



Université d'Angers

Faculté des Sciences

Master 2 Photonique, Signal et Imagerie

Année Universitaire 2014/2015

Rapport de stage

**Analyse d'Images Multibandes et Hyperbandes :
Stratégie de Détection d'Objets Diffus**

Date de Soutenance : 26 Juin 2015

Stagiaire :

Ali AHMAD

Rapporteur :

Professeur François CHAPEAU-BLONDEAU

Encadrants de stage :

Pr. Christophe COLLET
Dr. Ola AHMAD
MdC. Fabien SALZENSTEIN

Ce mémoire est écrit dans le cadre du stage effectué de 2 Mars jusqu'à 31 Juillet 2015 au sein de l'équipe MIV du laboratoire ICube - UMR CNRS 7357 de l'Université de Strasbourg.

*A mes parents,
A mes amis,*

" La seule source de connaissance est l'expérience "
- Albert Einstein -

Remerciements

Il me paraît important de remercier toutes les personnes qui ont participé de différentes façons à la réussite de mon stage et qui ont mis tout en œuvre pour que mon stage se déroule dans les meilleurs conditions possibles.

Je tiens à remercier mon responsable de stage Monsieur Christophe COLLET, professeur à l'Université de Strasbourg et directeur de l'équipe MIV du laboratoire ICube de m'avoir accueillie dans son équipe. Je le remercie pour sa qualité d'écoute, ses conseils professionnels et personnels, sa patience et sa bonne humeur. Sa rigueur scientifique et ses qualités humaines m'ont profondément touchée.

Mes remerciements s'adressent également à mon encadrant Monsieur Fabien SALZENSTEIN, maître de conférence à l'Université de Strasbourg. Son soutien, sa clairvoyance et ses compétences m'ont été d'une aide inestimable.

Je tiens à exprimer également mes profonds remerciements à mon encadrante Madame Ola AHMAD, la doctorante chercheuse au sein de l'équipe MIV du laboratoire pour sa qualité d'écoute, ses conseils professionnels et personnels, sa disponibilité, sa patience, sa bonne humeur, sa gentillesse et pour sa qualité de suivie.

Mes remerciements les plus chaleureux vont à tous les membres de l'équipe MIV pour leurs conseils occasionnels et leurs aides, en particuliers je remercie les stagiaires Zied ZOUCHE et Anthony CORADIN pour sa présence dans les moments difficiles et grâce à eux j'ai passé d'excellents moments.

Finalement, je termine par remercier le lecteur qui lit ce mémoire, en vous souhaitant une bonne lecture...

Table des matières

Résumé	12
Abstract	13
Introduction Générale	14
1 Imagerie Hyperspectrale	16
1.1 Introduction	16
1.2 Définition de l'imagerie hyperspectrale	17
1.3 Application de l'imagerie hyperspectrale	18
1.4 Formation des images hyperspectrales	18
1.5 Modèle mathématique d'une image hyperspectrale	19
1.6 Simulation des images hyperspectrales	20
1.6.1 Objets diffus	20
1.6.2 Paramètres de la simulation	20
1.7 Conclusion	23
2 Méthodes de détection : Etat de l'Art	24
2.1 Introduction	24
2.2 Conception d'un détecteur	24
2.3 Performance et Taux de fausse alarme constante (TFAC)	25
2.4 Méthodes de détection supervisées	26
2.4.1 Filtre Adapté	27
2.4.2 Détecteur Angulaire Adapté	27
2.4.3 Spectral Angle Mapper (SAM)	27
2.5 Méthodes de détection non-supervisées	28
2.5.1 Détecteur RX classique	28
2.5.2 RX Pondéré (WRX)	29
2.5.3 Détecteur d'Anomalie Causal Adaptatif (DACA)	29
2.5.4 Dual Window-based Eigen Separation Transform Anomaly Detector (DWEST-RX)	30
2.5.5 Nested Spatial Window-base Target Detector (NSWTD)	30
2.6 Conclusion	31
3 Poursuite des Composantes Anormales - PCA	32
3.1 Introduction	32
3.2 Algorithme PCA	32
3.2.1 Modélisation des données	32
3.2.2 Pré-traitement des données	33
3.2.3 Masque de Condition Initiale (MCI)	34
3.2.4 Poursuite de Projection : FastICA	34
3.2.5 Seuillage des cartes de détection	35
3.2.6 Unification des classes	36
3.2.7 Déblanchiment des données	36
3.3 Application de la Poursuite des Composantes Anormales	36

3.3.1	Résultats expérimentaux et discussions	37
3.4	Conclusion	50
	Conclusion Générale	50
	Annexe A Démonstration du modèle du système HSI	53
	Annexe B Simulation des HSI's	54
	Annexe C Kurtosis	56
	Bibliographie	59

Table des figures

1.1	<i>Imageurs et décomposition des spèctres électromagnétique</i>	16
1.2	<i>Profil spectral d'une pixel du cube de données</i>	17
1.3	<i>Modèle d'image hyperspectrale</i>	19
1.4	<i>Image Astronomique</i>	20
1.5	<i>Paramètres spatiaux d'un objet elliptique</i>	21
1.6	<i>Paramètres spectraux d'un pixel</i>	22
1.7	<i>Image hyperspectrale synthétique</i>	23
2.1	<i>Schématisation d'un détecteur à TFAC</i>	26
3.1	<i>Images des objets étendu et étendu tronqué</i>	37
3.2	<i>Images des objets étendus tronqués avant et après bruitage à différent niveaux du bruit</i>	38
3.3	<i>Signatures spectrales des objets de HSI 1.</i>	39
3.4	<i>Signatures spectrales des objets de HSI 2.</i>	39
3.5	<i>Signatures spectrales des objets de HSI 3</i>	39
3.6	<i>Les Masques de condition initial des images HSI 1, 2 et 3</i>	40
3.7	<i>Projcteurs de HSI 1</i>	41
3.8	<i>Projcteurs de HSI 2</i>	42
3.9	<i>Projcteurs de HSI 3</i>	43
3.10	<i>Carte de détection et de discrimination, cas d'objets étendus tronqué</i>	44
3.11	<i>Projcteurs d'une fausse alarme</i>	45
3.12	<i>Courbes ROC : P_d en fonction de TFAC pour différents SNR, cas d'objets étendus tronqués</i>	46
3.13	<i>Courbes ROC : P_{fa} en fonction de TFAC pour différents SNR, cas d'objets étendus tronqué</i>	47
3.14	<i>Courbes ROC : P_d en fonction de n_3 pour différents SNR à $\kappa = 10^{-4}$, cas d'objets étendus tronqués</i>	48
3.15	<i>Images des objets étendus avant et après bruitage</i>	49
3.16	<i>Cartes de discrimination, cas d'objets étendus</i>	49
3.17	<i>Courbes ROC : P_d en fonction de TFAC pour différents SNR, cas d'objets étendus</i>	50
B.1	<i>Etapes de la simulation d'une HSI</i>	55
C.1	<i>Kurtosis</i>	56

Liste des tableaux

3.1	<i>Paramètres des objets de HSI 1.</i>	39
3.2	<i>Paramètres des objets de HSI 2.</i>	39
3.3	<i>Paramètres des objets de HSI 3.</i>	39
3.4	<i>Paramètres spectraux détectés des objets de HSI 1.</i>	42
3.5	<i>Paramètres spectraux détectés des objets de HSI 2.</i>	42
3.6	<i>Paramètres spectraux détectés des objets de HSI 3.</i>	43
3.7	<i>Paramètres spectraux VT et détectés des objets étendus de HSI 4.</i>	49

Liste des Notations

Acronymes

<i>ACE</i>	<i>Adaptive Cosine Estimator</i>
<i>AMF</i>	<i>Adaptive Matched Filter</i>
<i>DACA</i>	<i>Détecteur d'Anomalie Causal Adaptatif</i>
<i>DWEST</i>	<i>Dual Window-based Eigen Separation Transform Anomaly Detector</i>
<i>GLRT</i>	<i>Generalized Likelihood Ratio Test</i>
<i>HSI</i>	<i>Hyperspectral Image</i>
<i>ICA</i>	<i>Independent Component Analysis</i>
<i>LRT</i>	<i>Likelihood Ratio Test</i>
<i>LSF</i>	<i>Line Spread Fonction</i>
<i>MCI</i>	<i>Masque de Condition Initial</i>
<i>NSWTD</i>	<i>Nested Spatial Window-base Target Detector</i>
<i>OPD</i>	<i>Orthogonal Projection Divergence</i>
<i>PCA</i>	<i>Poursuite des Composantes Anormales</i>
<i>PP</i>	<i>Poursuite de Projection</i>
<i>PSF</i>	<i>Point Spread Fonction</i>
<i>ROC</i>	<i>Receiver Operating Characteristic</i>
<i>RX</i>	<i>Détecteur d'anomalie Reed-Xiaoli</i>
<i>SNR</i>	<i>Signa to Noise Ratio , (Rapport Signal/Bruit)</i>
<i>SVD</i>	<i>Singular Value Decomposition</i>
<i>TFAC</i>	<i>Taux de Fausse Alarme Constante</i>
<i>TH</i>	<i>Test des Hypothèses</i>
<i>WRX</i>	<i>Weighted RX</i>

Matrices et vecteurs

$\Lambda_{(\cdot)}(\mathbf{y})$	<i>Sortie du détecteur pour un pixel spectral \mathbf{y}</i>
---------------------------------	---

Γ_y	Matrice de corrélation du pixel spectral y_i
$\Sigma_{(.)}$	Matrice de covariance, dimensions $n_3 \times n_3$
Σ_k	Matrice de configuration spatiale du $k^{\text{ème}}$ signal , dimensions 2×2
θ	Paramètres d'une distribution de probabilité estimés par maximum vraisemblance
s_k	Signal elliptique , $k=1,\dots,d$.
A	Vecteur de gain, dimensions $d \times 1$
B	Matrice de blanchiment, dimensions $n_3 \times n_3$
b^z	Vecteur d'intensité du fond dans une bande z , dimensions $1 \times M$
D	Matrice diagonale des valeurs propres, dimensions $n_3 \times n_3$
F	Matrice de déblanchiment, dimensions $n_3 \times n_3$
$m_{(.)}$	Vecteur spectral moyen du fond n_3 -dimensionnel
n^z	Bruit blanc gaussien dans une bande z , dimensions $1 \times M$
R	Images vectorielle des données blanchies , dimensions $n_3 \times M$
r	Pixel spectral blanchi , dimensions $n_3 \times 1$
S^z	Matrice de configuration des objets dans une bande z , dimensions $d \times M$
U	Matrice des vecteurs propres, dimensions $n_3 \times n_3$
V	Matrice des projecteurs V_j dans l'espace direct, dimensions $n_3 \times J$
w	Projecteur, dimensions $n_3 \times 1$
y	Pixel spectral , dimensions $n_3 \times 1$
W	Matrice des projecteurs w_j , dimensions $n_3 \times J$
H	Réponse optique du système hyperspectral
t	Vecteur d'intensité spectrale des objets, dimensions $n_3 \times 1$
t_B	Vecteur d'intensité des objets après blanchiment, dimensions $n_3 \times 1$
X	Image hyperspectrale 3D, dimensions $n_1 \times n_2 \times n_3$
Y	Images vectorielle des données hyperspectrales , dimensions $n_3 \times M$
Y_c	Images vectorielle des données hyperspectrales centrées, dimensions $n_3 \times M$
\tilde{R}	Matrice des données projetées , dimensions $n_3 \times M$

Scalaires

(x, y)	Coordonnée spatiale d'un pixel
β_k	Largeur spectrale du $k^{\text{ème}}$ objet
$\delta_{(.), (.)}$	Projection orthogonale divergente
η	Seuil de décision

$\hat{\beta}$	<i>Largeur spectrale déterminée</i>
\hat{z}	<i>Localisation spectrale déterminée</i>
κ	<i>Taux du fausse alarme constante TFAC</i>
μ_k	<i>Location spatiale du $k^{\text{ème}}$ objet</i>
σ_0^2	<i>Variance de l'intensité d'objets</i>
σ_n^2	<i>Variance du bruit</i>
h_0	<i>Fonction PSF 2D</i>
h_λ	<i>Fonction LSF 1D</i>
p	<i>Probabilité de la présence d'un objet elliptique</i>
d	<i>Nombre d'objets elliptiques dans l'image hyperspectrale</i>
J	<i>Nombre des classes spectrales d'une HSI</i>
M	$n_1 \times n_2$, <i>nombre des pixels</i>
n_3	<i>Dimension spectrale d'une image hyperspectrale</i>
n_1, n_2	<i>Dimensions spatiales d'une image hyperspectrale</i>
$p(\mathbf{y}/H_0)$	<i>Densité de probabilité conditionnelle sous H_0</i>
$p(\mathbf{y}/H_1)$	<i>Densité de probabilité conditionnelle sous H_1</i>
P_d	<i>Probabilité de détection</i>
P_{fa}	<i>Probabilité de fausse alarme expérimentale</i>
w_i, q_i	<i>Poids scalaires de chaque pixel spectral de l'image hyperspectrale</i>
z	<i>Coordonnée spectrale d'un pixel</i>

Divers

$(.)^T$	<i>Transpose</i>
$\chi_{n_3}^2$	<i>Loi de probabilité chi-deux de n_3 degré de liberté</i>
$\mathcal{N}(m, \sigma^2)$	<i>Loi de probabilité normale de moyen m et de variance σ^2</i>

Résumé

Les méthodes de détection et de classification des objets, supervisées et non-supervisées, sont largement utilisées en traitement d'images multi/hyperbandes dont le spectre de chaque pixel est considéré soit discret (de 4 à 10 bandes) dans le cas d'images multi-bandes, ou continu (au delà de centaines de bandes) pour l'image hyperbande. Cependant, dans certains cadres applicatifs tels que l'analyse des galaxies en astronomie ou l'identification des cellules en biologie, l'absence de la base d'apprentissage exige l'utilisation d'approches non-supervisées qui devront rester efficaces. Le critère de base de ces méthodes est la recherche de pixels ayant des caractéristiques spectrales différentes de celles du fond, ces pixels sont nommés des "anomalies". Ce sont des "valeurs aberrantes qui s'écartent des autres observations au point d'éveiller les soupçons d'avoir été générées par autre mécanisme" (*Hawkins, 1980*).

Dans ce rapport, nous présenterons la *Poursuite des Composantes Anormales (PCA)*, une méthode statistique non-supervisée qui porte sur la détection et la discrimination des objets rares dans une image hyperspectrale. La méthode citée combine deux approches : le test des hypothèses (HT) avec un taux de fausse alarme constante (TFAC) et la poursuite de projection (PP) basée sur l'algorithme ICA sous le critère de maximisation de Kurtosis. Cette méthode est appliquée sur des images hyperspectrales synthétiques incluant des objets étendus ou étendus tronqués à plusieurs niveaux du bruit, ceci afin d'évaluer les performances et la robustesse selon le niveau du bruit, et les différentes catégories d'objets.

Mots-Clés : Détection d'Anomalie, Taux de fausse alarme constante, Poursuite de Projection, Objets étendus, Objets étendus tronqué, Image Hyperspectrale.

Abstract

Object detection and classification methods, supervised and unsupervised, are widely used in Multi/ hyper bands image processing whose spectrum of each spectral pixel is considered to be discrete (4 to 10 bands) for multi band images, or continuous (over hundreds of bands) for hyperband images. However, in some application frameworks such as analysis of galaxies in astronomy or identification of biological cells, etc., the lack of the learning base requires the use of unsupervised approaches that will remain effective. The basic criterion of these methods is looking for pixels having different spectral characteristics from the background, these pixels are named "anomalies". These are "outliers that deviate from other observations to the point of arousing suspicion of having been generated by other mechanism" (*Hawkins, 1980*).

In this report, we present the anomalous component pursuit (ACP), an unsupervised statistical method involves the detection and discrimination of the rare objects in a hyperspectral image. The cited method combines two approaches : hypothesis testing (HT) with a constant false alarm rate (CFAR) and Projection Pursuit (PP) algorithm based on the independant component analysis (ICA) with the kurtosis maximization criterion. This method is applied to synthetic hyperspectral images including extended objects or extended truncated objects at several levels of noise in order to evaluate the performance and robustness according to the noise level, and the different categories of objects.

Keywords : Anomaly Detection, Constant false alarm rate, Projection Pursuit, Extended Truncated Objects, Extended Objects, Hyperspectral Image.

Introduction Générale

UNE image est la description du réel. Parfois monochrome, c'est à dire représentée en niveau de gris, et parfois couleur, elle se compose alors de trois canaux monochromatiques chacun décrit l'intensité de la scène dans une bande passante précise. Avec l'évolution des technologies, la conception des capteurs d'imagerie sera plus sophistiquée ce qui nous a permis de décrire une même scène pour plusieurs longueurs d'onde. Le nombre des bandes va d'une dizaine en imagerie multispectrale vers des centaines et des milliers en imagerie hyperspectrale. En effet, les images hyperspectrales fournissent une information plus détaillée des propriétés spectrales d'une scène et permettent une discrimination plus précise des objets que ne le permettent les images couleur (RVB) ou même les images multispectrales. À partir des images hyperspectrales, l'accès simultané à des informations spatiales et spectrales est possible et permet de caractériser les objets de manière très fine. Bien que les potentialités de la technologie hyperspectrale apparaissent relativement grandes, l'analyse et le traitement de ces données restent des procédures complexes et difficiles. De ce fait, exploiter ces quantités importantes de données représente un défi, et la plupart des méthodes d'analyse et d'interprétation sont encore en développement.

Ce stage a été réalisé de Mars à Juillet 2015 au sein de l'équipe de recherche **Modèles, Images et Vision (MIV)** dans le **Laboratoire des Sciences de l'Ingénieur**, de l'**Informatique** et de l'**Imagerie (ICube - UMR CNRS 7357- Université de Strasbourg)** dans le cadre du projet de groupe de recherche **PASEO (Probabilistic Analysis For Space And Earth Observations)** qui porte sur le développement de nouvelles méthodologies d'analyse des données astronomiques. Il a été financé par un financement institutionnel qui soutient des projets et des recherches sur les spectro-imageurs de nouvelle génération.

Le sujet du stage pose la problématique de la détection d'objets diffus de formes variées (étendue ou étendue tronquée, *e.g., galaxies, étoiles, etc.*) contenus dans une image hyperspectrale et noyés dans un fort bruit gaussien. L'objectif principal des travaux est de trouver une méthode statistique non-supervisée permettant de révéler spatialement et spectralement ces objets, étant donné qu'aucune données de "vérité-terrain" n'est disponible.

Ce manuscrit est réparti en trois chapitres. Le premier commence par une définition de l'imagerie hyperspectrale et ses applications. La formation d'une image hyperspectrale et le modèles mathématique des données ainsi que les paramètres de la simulation d'une image hyperspectrale contenant des objets diffus aléatoirement configurés sont ensuite

présentés.

Le deuxième chapitre est consacré à l'état de l'art des méthodes de détection. Nous montrerons un ensemble des méthodes de base, supervisées et non-supervisées, utilisées pour l'étude et la détection des objets dans les images hyperspectrales.

Le troisième chapitre est dédié à la présentation de la *Poursuite des Composantes Anormales (PCA)*, la méthode de détection mise en œuvre. Pour expliciter ces différentes étapes nous présenterons les résultats expérimentaux de l'application de PCA sur certains types d'images hyperspectrales simulées (*e.g.*, *Plusieurs niveaux du bruit, formes d'objets, etc*), ensuite nous étudierons la performance de la méthode par les courbes ROC.

Nous finirons par une conclusion générale et les perspectives envisagées.

Imagerie Hyperspectrale

1.1 Introduction

LA spectro-imagerie ("*spectral imaging*", *en anglais*) est née de la combinaison de l'imagerie et de la spectrométrie, a pour objet de générer des images résolues spectralement et spatialement. C'est donc une généralisation de l'imagerie en couleurs, à cette différence que le nombre de composantes spectrales (*bandes*) associées à chaque pixel de l'image n'est plus limité à trois Rouge, Bleu et Vert (*image couleur*), mais peut aller au-delà du centaine. Lorsque ce nombre est faible, autour de la dizaine de bandes au proche et moyen infrarouge (IR), on parle plutôt d'imagerie multispectrale qui produit des signatures spectrales discrètes, et d'imagerie hyperspectrale quand le nombre de bandes est continu allant de centaines au milliers [14]. La *figure 1.1* schématise la sensibilité spectrales des différents types d'imageurs évoqués. Nous nous intéressons dans notre étude à l'imagerie hyperspectrale fournie par des spectro-imageurs.




FIGURE 1.1 – Décomposition du spectre électromagnétique par différents types d’imageurs, (Réf : thèse A. Huck).

Dans ce chapitre introductif, nous définirons l’imagerie hyperspectrale et nous montrerons

ses applications, puis nous expliquerons la formation de l'image hyperspectrale et le modèle de données dans un cube tridimensionnel et enfin nous présenterons les paramètres pris en compte dans la simulation d'une telle image incluant des objets diffus.

1.2 Définition de l'imagerie hyperspectrale

L'imagerie hyperspectrale est une technique qui consiste à l'acquisition d'une image à haute résolution dans un grand nombre de bandes spectrales étroites et contiguës (de l'ordre de 10 nm) dans une gamme de longueurs d'onde donnée, généralement correspondant aux domaines du visible et du proche-infrarouge (400 à 2500 nm). Cette modalité d'imagerie permet d'exploiter au mieux l'information d'une scène. Il est ainsi possible d'identifier des objets en surface (ou des gaz/particules atmosphériques) et de mesurer leurs propriétés par l'analyse de leurs caractéristiques spectrales. L'imagerie hyperspectrale permet de reconnaître dans le pixel la signature spectrale (*figure 1.2*) des constituants qu'il contient, c'est-à-dire de les identifier, par exemple, la position en longueur d'onde des pics d'absorption spécifiques dépend de la composition chimique d'objets, et leur amplitude va quant à elle donner des indications sur la quantité (ou la concentration) des constituants présents [14].

Habituellement, une image hyperspectrale (HSI) tridimensionnelle (3D) \mathbf{X} est modélisée par un cube de données hyperspectrales contenant toutes les informations d'une scène dans deux dimensions spatiales (n_1, n_2) indiquant les positions des pixels et une dimension spectrale (n_3 , le nombre des bandes) correspondant à la réflectance des éléments de la scène en fonction de la longueur d'onde.

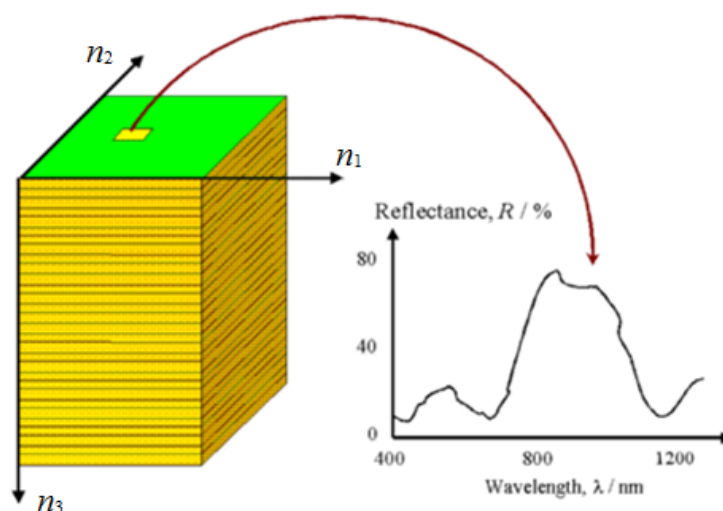


FIGURE 1.2 – Schématisation d'un cube hyperspectral de trois dimensions, spatiales : n_1, n_2 et spectrale : n_3 et le profil spectral d'un pixel du cube.

1.3 Application de l'imagerie hyperspectrale

La capacité de l'imagerie hyperspectrale à offrir une grande quantité informationnelle permet de réaliser des analyses beaucoup plus approfondies d'une scène réelle que les autres modalités d'imageries, ceci lui a donné une valeur qui l'a introduit dans plusieurs domaines applicatifs, nous citons par exemple [14],

- **La télédétection** : Utilisations agricoles pourraient inclure la détermination des variétés végétales, les conditions de l'eau et des éléments nutritifs.
- **Biologie** : L'imagerie hyperspectrale est largement utilisée en biologie, par exemple, elle est manipulée pour faire l'imagerie à fluorescence, pour estimer le degré de saturation du sang en oxygène par la mesure de spectres de l'hémoglobine, pour rechercher des traces de substances présentes sur des empreintes digitales et en plus, pour identifier les cellules cancéreuses.
- **Surveillance** : La surveillance militaire ou aérienne par l'imagerie thermique qui fait partie de l'imagerie hyperspectrale.
- **Astronomie** : En astronomie, on peut distinguer plusieurs axes d'utilisation de l'imagerie hyperspectrale, par exemples, la détermination de la composition chimique des corps observés (*e.g, galaxies, étoiles, etc*).
- ...

1.4 Formation des images hyperspectrales

Le modèle générale d'un système d'observation de l'imagerie hyperspectrale en un point $(x, y, z) \in \mathbb{R}^3$ peut être décrit comme suit [1],

$$X(x, y, z) = I(x, y, z) * H(x, y, z) + n(x, y, z) \quad (1.1)$$

où $I(x, y, z)$ est la valeur de la lumière réfléchiée de la position spatiale (x, y) sur la bande spectrale z , $n(x, y, z)$ représente le bruit instrumental qui peut être un mélange de bruit thermique, bruit de photons, et d'autres types de bruit. H est la réponse du système hyperspectrale dans les deux domaines spatial et spectral. En général et pour la simplicité, nous supposons que les fonctions des réponses spatiales et spectrales du système sont indépendantes c.à.d que les espaces spectrales et spatiales sont orthogonales et alors leurs fonctions peuvent être séparées de telle sorte que :

$$H(x, y, z) = h_\lambda(z) \cdot h_0(x, y) \quad (1.2)$$

Où, $h_\lambda(z)$ est la réponse spectrale (fonction LSF) en fonction de nombre de bande z et $h_0(x, y)$ est la réponse spatiale (fonction PSF) du système optique en fonction de (x, y) . Et par suite, un système d'observation hyperspectrale peut être représenté comme (*cf. Annexe A*),

$$X(x, y, z) = [I(x, y, z) * h_\lambda(z)] * h_0(x, y) + n(x, y, z) \quad (1.3)$$

Dans ce modèle, chaque valeur de $X(x, y, z)$ indique l'intensité de la lumière réfléchiée observée et codée par le système comme une image. La lumière réfléchiée représente à chaque localisation spatiale (x, y) de pixels le spectre de rayonnement sur les bandes, où les valeurs de la luminance spectrale sont le résultat de plusieurs facteurs : la réflectance spectrale des propriétés de surface et les effets liés à l'atmosphère, à l'éclairage et au

capteur. Les effets de capteurs sont introduits par le bruit de décalage et par la fonction caractérisant sa réponse, mais les facteurs d'éclairage et de l'absorption atmosphérique ont des effets multiplicatifs, *i.e.*, la réflectance spectrale de la surface doit être multiplié par ces effets. En fait, les effets de l'atmosphère ne se limitent pas à l'absorption de lumière seulement, mais à l'influence de la diffusion aussi. Néanmoins, la lumière diffusée à cause de l'atmosphère dépend des caractéristiques topographiques de la scène, et des variations spatiales des conditions atmosphériques et la lumière diffusée a des effets additifs sur la réflectance spectrale. De toute façon, la présence ou l'absence de la plupart de ces effets dépend de l'application, de la qualité de l'instrument et des conditions d'acquisition. Par exemple, dans les applications astronomiques, l'effet de la diffusion de la lumière disparaît, et les autres effets multiplicatives peuvent être réduites si l'acquisition sont prises en des meilleures conditions (ciel net, ...).

Dans la suite, nous ignorons les effets déjà cités et étant donné que l'image est soumise à des algorithmes de pré-traitement, nous considérons que la lumière réfléchiée est définie par les propriétés surfaciques des objets de la scène.

1.5 Modèle mathématique d'une image hyperspectrale

L'image hyperspectrale \mathbf{X} définie par un cube de donnée où chaque fréquence correspond à une image 2D de dimensions $n_1 \times n_2$ prise à une bande spectrale $z \in [1, \dots, n_3]$, peut être représentée par une matrice vectorielle \mathbf{Y} de dimensions $n_3 \times M$, avec $M = n_1 \times n_2$ est le nombre de pixels spectraux et n_3 le nombre de bandes spectrales (*figure 1.3*).




FIGURE 1.3 – Modèle d'une image hyperspectrale 3D , et la matrice 2D correspondante [1].

Chaque vecteur ligne de cette matrice correspond à un tranche du cube et il peut être écrit sous la forme du modèle linéaire suivant,

$$\mathbf{Y}^z = \mathbf{A}\mathbf{S}^z + \mathbf{b}^z + \mathbf{n}^z \quad (1.4)$$

Avec, $\mathbf{S}^z = [\mathbf{s}_1^z, \dots, \mathbf{s}_d^z]^T$ une matrice de configuration des intensités des objets de dimensions $d \times M$ où d est le nombre des objets dans la scène, $\mathbf{A} = [a_1, \dots, a_d]$ est le

vecteur ligne de pondération d -dimensionnel représentant l'amplitude de l'intensité de chaque objet (gain), \mathbf{b}^z est l'intensité du fond de dimensions $1 \times M$ et \mathbf{n}^z vecteur ligne M -dimensionnel du bruit blanc gaussien de moyenne zéro et de variance σ_n^2 .

1.6 Simulation des images hyperspectrales

Dans le cadre de l'étude des méthodes de détection des objets diffus, étendus et quasi-punctuels, un algorithme de simulation est adapté pour produire des images hyperspectrales incluant des objets diffus modélisés par des modèles elliptiques [3], en supposant que la réponse du système optique est idéale, c.à.d que la réponse est impulsionnelle tel que $h_0(x, y) = \delta(x, y)$ centrée aux pixels (x, y) et $h_\lambda(z) = \delta_\lambda(z)$ centrée à la bande z , avec x, y et z varies le long des dimensions spatiales et spectrale respectivement.

1.6.1 Objets diffus

Un objet diffus est l'objet qui reflète la lumière sur le capteur du système d'imagerie où son image sera généralement codé sous la forme d'une fonction gaussienne. Nous pouvons distinguer entre objet diffus étendu et objet étendu tronqué.

Pour mieux définir les termes étendus et étendu tronqué, nous référons comme exemple, à une image hyperspectrale astronomique (*figure 1.4*). L'étoile (entourée en rouge) est un exemple d'un objet étendu tronqué, où son profil d'intensité est de la forme d'une fonction gaussienne tronqué entre deux valeurs a et b (peut être rapproché de loi uniforme étroite), cependant, le profil d'intensité d'une galaxie caractérisant un objet étendu (entouré en vert) à la forme approximé d'une fonction gaussienne qui s'étale vers l'infinie.




FIGURE 1.4 – Image astronomique M102, NGC5866 NOAO/AURA/NSF. Exemple d'un objet étendu, entouré en vert, de profil gaussien et d'un objet étendu tronqué, entouré en rouge, de profil gaussien tronqué.

1.6.2 Paramètres de la simulation

Nous nous intéressons à la détection des objets diffus dans une image hyperspectrale à fond constant, aussi nous considérons que l'intensité du fond est nulle ($\mathbf{b}^z = 0$) pour la

simplicité, et donc le modèle de l'équation (1.4) sera,

$$\mathbf{Y}^z = \mathbf{A}\mathbf{S}^z + \mathbf{n}^z \quad (1.5)$$

La simulation des objets diffus est établie en utilisant le processus ponctuel marqué de Poisson. Ils sont configurés aléatoirement dans l'image hyperspectrale synthétique, alors que les paramètres qui gèrent le nombre, les positions géométriques, les valeurs des intensités et les localisations spectrales des objets sont les suivants : (cf. Annexe B)

- **Les centres \mathbf{O}** : Ils sont une collection des points aléatoirement positionnées dans l'espace de l'image selon la distribution de poisson.
- **Grand axe (\mathbf{a}) et petit axe (\mathbf{b})** : Configurés par des distributions uniforme entre $[a_1, a_2]$ et $[b_1, b_2]$.
- **Orientation** : Selon une angle θ (en rad) configurée par une distribution uniforme entre $[0, \pi]$, (voir figure 1.5).
- **Signal \mathbf{S} d'un objet** : Généré par une fonction gaussienne, (voir exemple figure 1.7).
- **Vecteur du gain \mathbf{A}** : Généré par une distribution gaussienne de moyenne $\mu_0 = 10$ et de matrice de covariance Σ_d de dimensions $d \times d$, où les coefficients pondérés des intensités des objets sont supposées indépendantes, et donc la matrice de covariance sera $\sigma_0^2 \mathbf{I}_d$, avec \mathbf{I} est une matrice d'identité de dimensions $d \times d$ et la valeur de la variance choisie est $\sigma_0^2 = 5$.

Alors, l'intensité finale d'un objet elliptique sera égale à $\mathbf{A}\mathbf{S}^z$ et à noter que la présence où l'absence de l'objet (k) est déterminée par son gain a_k dans le vecteur \mathbf{A} , par exemple, pour $a_k = 0$, l'objet (k) est absent.




FIGURE 1.5 – Paramètres spatiaux d'un objet elliptique. O : centre du signal, θ : orientation, a : grand axe, b : petit axe.

Enfin, nous pouvons modéliser chaque objet elliptique \mathbf{s}_k , $k=1,\dots,d$, avec une fonction gaussienne anisotrope comme suit,

$$\mathbf{s}_k(z, \mu_k, \Sigma_k, z_k, \beta_k) = \frac{1}{(2\pi)^{\frac{3}{2}} \beta_k |\Sigma_k|^{\frac{1}{2}}} e^{-\frac{(U-\mu_k)^T \Sigma_k (U-\mu_k)}{2}} \times e^{-\frac{(z-z_k)^2}{2\beta_k^2}} \quad (1.6)$$

Avec, $\mathbf{U}=[x,y]^T$, $\mu_k=[x_k, y_k]^T$ est la location spatiale du signal \mathbf{s}_k , Σ_k est une matrice de dimension 2×2 des paramètres spatiaux (dimension et orientation), z_k localisation spectrale du signal et β_k la largeur de son profil spectral gaussien (*figure 1.6*).






FIGURE 1.6 – Paramètres spectraux d'un pixel. β_k : largeur spectrale, z_k : localisation sur l'axe des bandes.

Pour rapprocher du modèle défini précédemment (*équation 1.5*), un bruit blanc gaussien non-corrélé de moyenne \mathbf{m}_n et de matrice de covariance diagonale $\Sigma_n = \sigma_n^2 \mathbf{I}_{n_3}$ de dimensions $n_3 \times n_3$ est ajouté à l'image simulée, nous présentons dans la *figure (1.7)*, comme exemple, une image moyennée sur toutes les bandes du cube hyperspectrale simulée avant et après l'ajout du bruit.



(a) HSI



(b) HSI bruitée

FIGURE 1.7 – *a : Une image hyperspectrale de dimension $200 \times 200 \times 200$ inclue 7 objets elliptiques. b : La même image hyperspectrale avec un bruit gaussien additif d'écart $\sigma_n = 3$.*

1.7 Conclusion

Dans ce chapitre, nous avons présenté en général le principe de l'imagerie hyperspectrale, ses applications et les facteurs qui interviennent dans la formation des images, concernant les effets de l'environnement et du systèmes d'acquisition (PSF et LSF). Nous avons montré encore l'algorithme de la simulation qui permet d'avoir des images hyperspectrales contenant les objets diffus qui nous intéressent dans le développement d'une stratégie de détection.

Dans le chapitre suivant, nous présenterons les travaux réalisés concernant la détection des objets dans les images hyperspectrales. Ils s'agira de dresser un bref état de l'art sur les détecteurs utilisés, en s'intéressant aux méthodologies de la détection non-supervisée.

Méthodes de détection : Etat de l'Art

2.1 Introduction

UN grand nombre d'algorithmes de détection hyperspectrale ont été développés et utilisés au cours des dernières décennies. Ces algorithmes sont de type : supervisés et non supervisés.

En plus, il existe deux observations principales concernant ces algorithmes. Tout d'abord, un algorithme de détection est d'autant plus performant que le spectre de l'objet cherché est proche des spectres de fond. Deuxièmement, les algorithmes de correspondances spectrales (supervisée, en anglais *matching algorithm*) présentent de meilleures performances que les détecteurs non-supervisés, parce qu'ils cherchent des objets prédéfinies spectralement [5].

2.2 Conception d'un détecteur

En générale, la conception mathématique d'un détecteur est fournie par un domaine statistique connu sous le nom de test des hypothèses. Il existe certaines approches pour une conception systématique des algorithmes de détection. En effet, l'utilisation du test de rapport de vraisemblance (*en anglais, likelihood ratio (LR) test*) permet de bénéficier de plusieurs avantages. Ce test minimise le risque associé avec les décisions incorrectes et il conduit à des détecteurs qui sont optimaux pour une large gamme de critères de performance, y compris la maximisation de la séparation entre les spectres des objets cherchés et ceux du fond [18]. En vue d'une analyse théorique, les pixels spectraux \mathbf{y} de dimensions n_3 -dimensionnels sont traités comme des vecteur aléatoires qui suivent une distribution de probabilité spécifique. Donc, pour une observation, nous envisageons de choisir entre les hypothèses suivantes :

$$\begin{cases} H_0 : \text{Objet absent} \\ H_1 : \text{Objet présent} \end{cases}$$

Supposons maintenant que la densité de probabilité conditionnelle de \mathbf{y} sous l'hypothèse

H_0 est $p(\mathbf{y}/H_0)$ et sous H_1 est $p(\mathbf{y}/H_1)$, alors le LRT est,

$$\Lambda_{LRT}(\mathbf{y}) = \frac{p(\mathbf{y}/H_1)}{p(\mathbf{y}/H_0)} \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.1)$$

Avec, η est le seuil de décision. Si la valeur de $\Lambda_{LRT}(\mathbf{y})$ dépasse la valeur du seuil, alors l'hypothèse H_1 est sélectionnée, si non, H_0 est choisie.

En pratique, et lorsque la distribution de probabilité suivie par un pixel contient un nombre de paramètres θ déterministes inconnus alors ils sont déterminés par l'estimation au sens du maximum de vraisemblance (MV), et dans ce cas, le test est appelé rapport de vraisemblance généralisé (*en anglais, Generalized Likelihood Ratio Test (GLRT)*) qui s'écrit comme suit,

$$\Lambda_{GLRT}(\mathbf{y}) = \frac{\max_{\theta_1} p(\mathbf{y}; \theta_1/H_1)}{\max_{\theta_0} p(\mathbf{y}; \theta_0/H_0)} \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.2)$$

Pour plus de clarification, supposons que les pixels spectraux \mathbf{y} , suivent une distribution gaussienne multivariée dont la densité de probabilité est la suivante,

$$p(\mathbf{y}) = \frac{1}{(2\pi)^{\frac{n_3}{2}} |\Sigma|^{\frac{1}{2}}} e^{[-\frac{1}{2}(\mathbf{y}-\mathbf{m})^T \Sigma^{-1}(\mathbf{y}-\mathbf{m})]} \quad (2.3)$$

Où, \mathbf{m} le vecteur moyen n_3 -dimensionnel de la distribution et Σ la matrice de covariance de dimensions $n_3 \times n_3$ sont les paramètres à estimer par maximum à vraisemblance (MV) tel que $\tilde{\theta} = (\tilde{\mathbf{m}}, \tilde{\Sigma})$. Le modèle d'un pixel \mathbf{y} selon les deux hypothèses H_0 et H_1 sera,

$$\begin{cases} H_0 : \mathbf{y} = \mathbf{n} \sim \mathcal{N}(\tilde{\mathbf{m}}, \tilde{\Sigma}_n) \\ H_1 : \mathbf{y} = (\mathbf{t} - \tilde{\mathbf{m}}) + \mathbf{n} \sim \mathcal{N}(\mathbf{t}, \tilde{\Sigma}_n) \end{cases} \quad (2.4)$$

Avec, $\mathbf{t} = (a\mathbf{S})$ est le spectre de l'objet où a est le coefficient du gain et \mathbf{S} est le vecteur de configuration de l'intensité de l'objet et \mathbf{n} est le vecteur bruit n_3 -dimensionnel sur le pixel \mathbf{y} .

Parfois, l'estimation des paramètres s'effectuera par maximum a *posteriori* en considérant que la distribution a *priori* est Laplacienne. Cette méthode d'estimation est plus performante que le MV en présence de quelque loi spécifique et de bruit gaussien [12].

2.3 Performance et Taux de fausse alarme constante (TFAC)

Habituellement, la performance d'un détecteur est étudiée par la courbe ROC (*Receiver Operating Characteristic*). Cette courbe présente la probabilité de la détection P_d (Probabilité qu'un pixel détectée appartient à un objet) en fonction de la probabilité de fausse alarme P_{fa} (Probabilité qu'un pixel du fond soit détecté comme un pixel d'objet) pour un seuil de décision η . Ces probabilités sont définies par,

$$P_d = p(\Lambda(\mathbf{y}) > \eta; H_1) = \int_{\eta}^{\infty} p(\mathbf{y}/H_1) d\mathbf{y} \quad (2.5)$$

$$P_{fa} = p(\Lambda(\mathbf{y}) > \eta; H_0) = \int_{\eta}^{\infty} p(\mathbf{y}/H_0) d\mathbf{y} \quad (2.6)$$

La complexité dans la modélisation d'un détecteur reste au niveau du choix d'un seuil de décision η qui maintient la probabilité de fausse alarme négligeable. Il existe plusieurs critères pour le choix du seuil lorsque les probabilités conditionnelles sont connues. Par exemple, le critère de Bayes utilisé largement en classification et en détection, permet le calcul de η qui minimise la probabilité de fausse alarme P_{fa} , cependant, ce critère n'est pas valable en détection où la probabilité d'occurrence d'objets d'intérêts dans l'image est faible, puisque la P_{fa} peut être minimisée par la classification de chaque pixel comme un pixel du fond. Pour cette raison, le seuil qui maximise la probabilité de détection correcte P_d en fixant la probabilité de fausse alarme à une valeur $P_{fa} \leq \kappa$ est sélectionné, c'est le critère de Neyman-Pearson [18].

En pratique, un processus de taux de fausse alarme constante (TFAC) induit par le rapport de vraisemblance est opéré pour assurer la variation automatique du seuil. Ce processus est basé principalement sur le modèle assigné au fond et il est utilisé lorsque tous les paramètres statistiques de la distribution sont connus. L'objectif de l'algorithme TFAC est la détermination du seuil de détection η qui est relativement immune au niveau du bruit et aux variations du fond et permet la détection des objets pour un taux de fausse alarme constante κ (figure 2.1).




FIGURE 2.1 – Schématisation d'un détecteur à taux de fausse alarme fixe. Les spectres \mathbf{y} multidimensionnels sont à l'entrée du détecteur statistique, puis le test de détection (TD) est comparé avec un seuil déterminé pour un taux de fausse alarme fixe qui utilise un modèle statistique du fond pour décider si l'objet cible existe dans le pixel spectral ou non [18].

2.4 Méthodes de détection supervisées

Les détecteurs supervisés sont ceux qui nécessitent une connaissance spectrale de l'objet d'intérêt. Ces méthodes basées sur la mesure du degré de corrélation entre le spectre d'un pixel d'intérêt et les spectres stockés dans un dictionnaire pour identifier

les objets. Les spectres de références des objets d'intérêt peuvent être obtenu à partir d'une librairie ou d'un pixel d'intérêt déjà identifié.

2.4.1 Filtre Adapté

Le filtre adapté ou "*Adaptive Matched Filter (AMF) en anglais*" est un filtre linéaire statistique qui maximise le rapport signal-bruit en présence de bruit gaussien additive, proposé par (Reed, Mallet et Brennan (RMB), 1974) [17], utilisé comme un détecteur à taux de fausse alarme constante (TFAC) dans [6] et appliqué en imagerie hyperspectrale dans [18]. Un détecteur nécessite la connaissance du vecteur moyen et les matrices de covariance de l'objet et de la distribution du fond. Ces paramètres sont inconnus et ils sont estimés par MV sous conditions que la présence des objets dans l'image est rare, c.à.d, la matrice de covariance et le vecteur moyen de toute l'image sont égaux à celle du fond ($\mathbf{m} = \mathbf{m}_n$ et $\mathbf{\Sigma} = \mathbf{\Sigma}_n$) alors,

$$\tilde{\mathbf{m}} = \frac{1}{M} \sum_{i=1}^M \mathbf{y}_i = \tilde{\mathbf{m}}_n \quad (2.7)$$

Et,

$$\tilde{\mathbf{\Sigma}} = \frac{1}{M} \sum_{i=1}^M (\mathbf{y}_i - \tilde{\mathbf{m}})(\mathbf{y}_i - \tilde{\mathbf{m}})^T = \tilde{\mathbf{\Sigma}}_n \quad (2.8)$$

Typiquement, les spectres de références \mathbf{t} des objets sont extraits d'une bibliothèque ou à partir d'un nombre des spectres connus des pixels observés dans les mêmes conditions. Finalement, le détecteur à filtre adapté est donnée par,

$$\Lambda_{AMF}(\mathbf{y}) = \frac{(\mathbf{t} - \tilde{\mathbf{m}})^T \tilde{\mathbf{\Sigma}}^{-1} (\mathbf{y} - \tilde{\mathbf{m}})}{(\mathbf{t} - \tilde{\mathbf{m}})^T \tilde{\mathbf{\Sigma}}^{-1} (\mathbf{t} - \tilde{\mathbf{m}})} \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.9)$$

2.4.2 Détecteur Angulaire Adapté

Le détecteur angulaire adapté ou "*en anglais, Adaptive Cosine Estimator (ACE)*" est la version sub-pixel du détecteur AMF. Il est utilisé comme un détecteur à TFAC pour la discrimination spectrales entres les objets [9], [16]. Le modèle d'un pixel \mathbf{y} pour ce détecteur est donné par,

$$\begin{cases} H_0 : \mathbf{y} = \mathbf{n} \sim \mathcal{N}(\tilde{\mathbf{m}}, \tilde{\mathbf{\Sigma}}_n) \\ H_1 : \mathbf{y} = (\mathbf{t} - \tilde{\mathbf{m}}) + \tau^2 \mathbf{n} \sim \mathcal{N}(\mathbf{t}, \tau^2 \tilde{\mathbf{\Sigma}}_n) \end{cases} \quad (2.10)$$

La matrice de covariance du pixel sous H_1 est proportionnelle à celle du fond, et le facteur τ^2 est lié au taux de remplissage du spectre de l'objet dans le pixel. Le test de détection est une variation de GLRT et il est défini par,

$$\Lambda_{ACE}(\mathbf{y}) = \frac{[(\mathbf{t} - \tilde{\mathbf{m}})^T \tilde{\mathbf{\Sigma}}^{-1} (\mathbf{y} - \tilde{\mathbf{m}})]^2}{[(\mathbf{t} - \tilde{\mathbf{m}})^T \tilde{\mathbf{\Sigma}}^{-1} (\mathbf{t} - \tilde{\mathbf{m}})][(\mathbf{y} - \tilde{\mathbf{m}})^T \tilde{\mathbf{\Sigma}}^{-1} (\mathbf{y} - \tilde{\mathbf{m}})]} \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.11)$$

2.4.3 Spectral Angle Mapper (SAM)

Le SAM est un algorithme géométrique supervisé, développé par (Boardman, 1993) et il est utilisé pour les applications de détection, de classification et de discrimination

en imagerie hyperspectrale[19],[8]. Cette méthode est basée sur le calcul de l'angle entre deux pixels spectraux, le pixel d'intérêt \mathbf{y} et le pixel de référence \mathbf{t} . Le test SAM est exprimé en forme vectorielle comme suit,

$$\Lambda_{SAM}(\mathbf{y}) = \frac{\mathbf{t}^T \mathbf{y}}{(\mathbf{t}^T \mathbf{t})^{\frac{1}{2}} (\mathbf{y}^T \mathbf{y})^{\frac{1}{2}}} \quad (2.12)$$

Cette équation doit donner une valeur entre 0 et 1 ($0 \leq \Lambda_{SAM} \leq 1$) pour un pixel spectral caractérisant la réflectance d'un objet. Deux pixels similaires doivent avoir une valeur de Λ_{SAM} proche de 1 qui correspond à un petit angle entre les deux vecteurs formés par ces pixels.

Le SAM est un algorithme de détection basique rapide avec un coût de calcul négligeable et il ne dépend que de la forme spectrale de l'objet. En plus, il ne dépend pas des paramètres de la distribution des données spectrales (covariance et moyen) comme l'ACE. Cependant, l'ACE reste plus robuste au niveau de la détection que le SAM [20].

2.5 Méthodes de détection non-supervisées

La détection d'anomalie est une méthode de détection non-supervisée manipulée dans le sens de l'analyse spatiale et spectrale des objets, c'est une tâche importante pour l'exploitation des données hyperspectrales. C'est un algorithme qui ne nécessite pas des connaissances *a priori* de l'objet d'intérêt. Chaque pixel spectral qui ne correspond pas à un modèle du fond est déclaré comme un pixel anormale.

2.5.1 Détecteur RX classique

L'algorithme RX classique ou RX globale est développé par (Reed and Yu, 1993), formulé sous deux hypothèses. La première modélise le fond comme une distribution gaussienne multivariée ($\mathcal{N}(\mathbf{m}, \mathbf{\Sigma})$) des paramètres inconnus estimés par maximum à vraisemblance, et la deuxième modélise l'objet anormale comme une combinaison linéaire entre la signature d'objet et le bruit du fond. Cet algorithme est utilisé dans la plupart des applications de détection non-supervisée en imagerie hyperspectrale [15],[21]. Comme le AMF et le ACE, il est basé sur le rapport de vraisemblance généralisé (GLR), et son équation est donnée par :

$$\Lambda_{RX}(\mathbf{y}_i) = (\mathbf{y}_i - \tilde{\mathbf{m}})^T \tilde{\mathbf{\Sigma}}^{-1} (\mathbf{y}_i - \tilde{\mathbf{m}}) \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.13)$$

C'est la distance de Mahalanobis qui quantifie le degré de corrélation entre les spectres du fond et les spectres des cibles, où \mathbf{y}_i est le pixel spectral au position $i \in [1, \dots, M]$, $\tilde{\mathbf{m}}$ et $\tilde{\mathbf{\Sigma}}$ sont le vecteur moyen de dimensions $n_3 \times 1$ et la matrice spectral de covariance de dimensions $n_3 \times n_3$ respectivement et ils sont estimés par MV. L'algorithme RX utilise un taux de fausse alarme fixe pour déterminer le seuil de décision η .

Un autre détecteur RX existe connu sous le nom " algorithme RX local". Il est plus important puisque le RX globale n'est pas capable de détecter des objets anormaux de petites dimensions et qui sont distincts seulement de leurs voisinages [4]. Une fenêtre locale sera déplacée sur toute l'image et dans l'équation (2.13) la matrice de covariance

et le vecteur moyen global sont remplacés par ceux de la fenêtre locale. Ce détecteur retourne un taux de détection élevé. Toutefois, la taille de fenêtre est inconnue, et il n'existe pas une méthode universelle pour calculer ses dimensions, un autre problème est que le processus de détection est expansif au sens du temps de calcul dû à un calcul répété de la matrice de covariance dans chaque fenêtre locale.

2.5.2 RX Pondéré (WRX)

Ce détecteur développé par (Hsuan, 2005) est utilisé lorsque la probabilité de la présence des objets anormaux est grande. Dans ce cas une matrice de covariance simple ne sera plus valable pour présenter la distribution du fond. Il consiste à attribuer un poids approprié à chaque pixel, il fournit alors des différents poids pour les pixels en fonction de leurs caractéristiques, d'une manière à obtenir un meilleur équilibre entre les pixels d'objets et le fond dans le processus de détection [11]. La matrice de covariance pondérée Σ_w s'écrit comme suit,

$$\Sigma_w = \frac{\sum_{i=1}^M w_i (\mathbf{y}_i - \mathbf{m}_w)(\mathbf{y}_i - \mathbf{m}_w)^T}{\sum_{i=1}^M w_i} \quad (2.14)$$

Où le vecteur moyen pondéré \mathbf{m}_w est données par :

$$\mathbf{m}_w = \frac{\sum_{i=1}^M q_i \mathbf{y}_i}{\sum_{i=1}^M q_i} \quad (2.15)$$

Avec, w_i et q_i sont les poids scalaires de chaque pixel spectral de l'image et ils dépendent du pixel \mathbf{y} , du moyen \mathbf{m} de \mathbf{Y} et le moyen pondéré \mathbf{m}_w par :

$$q_i = \frac{1}{1 + \|\mathbf{y}_i - \mathbf{m}\|} \quad (2.16)$$

$$w_i = \frac{1}{1 + \|\mathbf{y}_i - \mathbf{m}_w\|} \quad (2.17)$$

Finalement, l'algorithme WRX s'écrit :

$$\Lambda_{WRX}(\mathbf{y}_i) = (\mathbf{y}_i - \mathbf{m}_w)^T \Sigma_w^{-1} (\mathbf{y}_i - \mathbf{m}_w) \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.18)$$

2.5.3 Détecteur d'Anomalie Causal Adaptatif (DACA)

Cet algorithme est proposé par (Chang et Hsueh, 2003). Il s'agit d'un détecteur où les fortes signatures des pixels anormaux détectés sont éliminées lors du processus de détection en raison de leurs effets indésirables sur la détection des pixels anomaux suivants. La matrice de covariance est remplacée par la matrice de corrélation définie par la différence entre la matrice de corrélation $\Gamma_{\mathbf{y}_i}$ du pixel spectral \mathbf{y}_i en cours de traitement et les pixels déjà détectés [13]. La matrice de corrélation est définie par,

$$\tilde{\Gamma}_{\mathbf{y}_i} = \Gamma_{\mathbf{y}_i} - \sum_{j \in \Delta_i} c_j c_j^T \quad (2.19)$$

Avec, Δ_i est l'ensemble des pixels $\mathbf{c}_j \in \mathbf{y}_i$ anormaux détectés et

$$\mathbf{\Gamma}_{\mathbf{y}_i} = \frac{1}{i} \sum_{j=1}^i \mathbf{y}_j \mathbf{y}_j^T \quad (2.20)$$

Par conséquence, l'équation du détecteur sera,

$$\Lambda_{DACA}(\mathbf{y}_i) = \mathbf{y}_i^T \tilde{\mathbf{\Gamma}}_{\mathbf{y}_i}^{-1} \mathbf{y}_i \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.21)$$

Un avantage de cet algorithme est qu'il peut être utilisé dans la détection en temps réel puisqu'il ne nécessite pas le calcul de la matrice de covariance et du vecteur moyen de l'image hyperspectrale.

2.5.4 Dual Window-based Eigen Separation Transform Anomaly Detector (DWEST-RX)

Il est développé par (Kwon et al, 2003). C'est un détecteur local où deux fenêtres sont utilisées, la première (interne) pour détecter les objets anormaux à l'intérieur de celle-ci et la deuxième (externe) pour modéliser le fond qui lui entoure [7]. L'équation du détecteur DWEST-RX est ,

$$\Lambda_{DWEST-RX}(\mathbf{y}) = |\mathbf{m}_{diff}^T \mathbf{C}_{ext}^{-1} \mathbf{m}_{diff}| \underset{H_0}{\overset{H_1}{\geq}} \eta \quad (2.22)$$

Avec, \mathbf{m}_{diff} est la différence entre le vecteur moyen \mathbf{m}_{ext} de la fenêtre externe et le vecteur moyen \mathbf{m}_{int} de la fenêtre interne, et \mathbf{C}_{ext} est la matrice de covariance du bruit qui existe dans la fenêtre externe.

2.5.5 Nested Spatial Window-base Target Detector (NSWTD)

Ce détecteur est une extension de DWEST, il est proposé par (Liu et Chang, 2004). Trois fenêtres sont utilisées dans cette méthode : interne, intermédiaire et externe. Les deux premières servent à déterminer la plus faible et la plus forte anomalies respectivement et la troisième pour modéliser le fond [13].

Cet algorithme utilise la projection divergence orthogonal (ou *Orthogonal Projection Divergence OPD en anglais*) comme un critère de mesure.

En général, le *OPD* est défini par,

$$OPD_{\mathbf{y}_i, \mathbf{y}_j} = \sqrt{\mathbf{y}_i \mathbf{P}_{\mathbf{y}_j}^\perp \mathbf{y}_i + \mathbf{y}_j \mathbf{P}_{\mathbf{y}_i}^\perp \mathbf{y}_j} \quad (2.23)$$

Avec, $\mathbf{y}_{m=i,j}$ sont des pixels spectraux n_3 -dimensionnelles et,

$$\mathbf{P}_{\mathbf{y}_m}^\perp = \mathbf{I}_{n_3} - \mathbf{y}_m (\mathbf{y}_m^T \mathbf{y}_m)^{-1} \mathbf{y}_m^T \quad (2.24)$$

Dans l'algorithme le OPD est implementé deux fois. La première fois entre les fenêtres internes et intermédiaires,

$$\delta_{int,inter}(\mathbf{y}) = OPD(\mathbf{m}_{int}, \mathbf{m}_{diff,1}) \quad (2.25)$$

Avec , \mathbf{m}_{int} et $\mathbf{m}_{diff,1}$ sont des vecteurs n_3 -dimensionnel de la moyenne de la fenêtre intermédiaire et de la différence entre les deux vecteurs moyens intermédiaires et internes respectivement.

Et la deuxième fois entre les fenêtres intermédiaires et externes,

$$\delta_{inter,ext}(\mathbf{y}) = OPD(\mathbf{m}_{inter}, \mathbf{m}_{diff,2}) \quad (2.26)$$

Où , $\mathbf{m}_{diff,2}$ est le vecteur de la différence entre les deux vecteurs moyens externe et intermédiaire.

Et par suite, l'équation finale du NSWTD est,

$$\Lambda_{NSWTD}(\mathbf{y}) = \max(\delta_{int,inter}(\mathbf{y}), \delta_{inter,ext}(\mathbf{y})) \quad (2.27)$$

Cet algorithme à l'avantage de détecter les pixels anormaux de faible intensité spectrale alors de fournir un nombre de détection correcte élevé.

2.6 Conclusion

Plusieurs méthodes de détection spectrale et spatiale des objets ont été développées pour bien analyser le contenu informatif d'une image hyperspectrale. Dans ce chapitre, nous avons présenté un nombre des méthodes de détection basées principalement sur la modélisation statistique des données et le test des hypothèses. Plusieurs algorithmes de réduction des dimensions ont été ajoutés sur ces méthodes pour l'amélioration de la performance de détection et les rendre plus rapide. Par exemple, la fusion analytique des bandes est combinée avec le détecteur d'anomalie RX dans [21] pour optimiser la détection des objets de faibles dimensions dans une image hyperspectrale. Dans [10], la transformé en ondelette est combinée avec les détecteurs d'anomalies pour extraire les approximations du signal hyperspectrale qui contiennent les informations d'intérêt et la détection de objets en diminuant le temps de calcul.

Dans le chapitre suivant, nous expliciterons la "Poursuite des Composantes Anormales (PCA)", une méthode statistique non-supervisée de détection des anomalies. Puis nous présenterons l'application de PCA sur des images hyperspectrales synthétiques contenant des objets diffus afin d'étudier la capacité de cette méthode à la détection des différents types d'objets.

Poursuite des Composantes Anormales - PCA

3.1 Introduction

DANS le but de la détection spatiale et la classification spectrale des objets diffus, la "Poursuite des Composantes Anormales (PCA)" [15] est appliquée sur les images hyperspectrales. Cette méthode non-supervisée combine deux approches : La poursuite de projection (PP) et le test des hypothèses (HT). En général, la Poursuite de projection sert à trouver les projections linéaires qui apparaissent les informations utiles dans des données multidimensionnelles, tandis que le test des hypothèses est la comparaison d'un test statistique avec un seuil de décision pour décider si une donnée appartient à une des deux hypothèses.

Dans la méthode étudiée, la poursuite de projection est appliquée afin de rechercher les classes spectrales auxquelles appartiennent les pixels spectraux des objets existant dans une image hyperspectrale et le test des hypothèses avec un taux de fausse alarme fixe " κ " pour calculer un masque binaire qui sera le critère pour avoir une détection spatiale et spectrale non-supervisée.

Dans ce chapitre, nous expliciterons la stratégie de la détection suivie. Nous présenterons dans une première partie les différentes approches théorique de la méthode, et dans une deuxième les résultats de l'application de la poursuite de composante anormale sur deux types des images hyperspectrales synthétiques de différents niveaux du bruit, avec objets étendus et avec objets étendus tronqués. Finalement, nous étudierons la performance et la validité de la méthode par les courbes ROC.

3.2 Algorithme PCA

3.2.1 Modélisation des données

L'algorithme de détection PCA est appliqué sur la matrice hyperspectrale \mathbf{Y} (cf. section 1.5) où chaque pixel \mathbf{y}_i , avec $i \in [1, \dots, M]$, est désigné par le modèle suivant,

$$\mathbf{y}_i = \mathbf{t}_i + \mathbf{n}_i \tag{3.1}$$

Avec, $\mathbf{t}_i = (a\mathbf{S})_i$ est le vecteur colonne n_3 -dimensionnel d'intensité spectrale des objets au position i et \mathbf{n}_i est le vecteur du bruit additive le long des bandes spectrales de dimensions $n_3 \times 1$.

\mathbf{y}_i comme est défini, est une réalisation aléatoire qui peut appartenir au fond sous l'hypothèse H_0 ou peut être considéré comme un pixel d'un objet anormale sous H_1 , donc l'adaptation de ces hypothèses selon l'algorithme RX nous permet de les formuler comme suit,

$$\begin{cases} H_0 : \mathbf{y} = \mathbf{n} \sim \mathcal{N}(0, \Sigma_n) \\ H_1 : \mathbf{y} = \mathbf{t} + \mathbf{n} \sim \mathcal{N}(\mathbf{t}, \Sigma_n) \end{cases} \quad (3.2)$$

3.2.2 Pré-traitement des données

Le pré-traitement est une étape essentiel de l'algorithme de détection à tester, sa nécessité apparait au niveau de la décorrélation spectrale des données. En général, cette étape s'achève par la centralisation des données, c.à.d, soustraction du vecteur moyenne \mathbf{m}_Y selon,

$$\mathbf{Y}_c = \mathbf{Y} - \mathbf{m}_Y \mathbb{1}_{1,M} \quad (3.3)$$

Avec $\mathbb{1}$, matrice des uns de dimension $1 \times M$ et le vecteur moyenne $\mathbf{m}_{Y_c} = 0$, suivie par une étape de blanchiment avec laquelle nous obtiendrons la matrice des données blanchies \mathbf{R} où ces composantes sont non-corrélées et de la même variance,

$$\mathbf{R} = \mathbf{D}^{-\frac{1}{2}} \mathbf{U}^T \mathbf{Y}_c \quad (3.4)$$

Avec, la matrice diagonale \mathbf{D} et la matrice \mathbf{U} de dimension $n_3 \times n_3$ contiennent les valeurs et les vecteurs propres respectivement et elles sont déterminées à partir de *Singular value decomposition* (SVD). Le vecteur moyenne $\mathbf{m}_R=0$ et la matrice de covariance $\Sigma_R=\mathbf{I}_{n_3}$ de dimensions $n_3 \times n_3$.

Nous rappelons qu'en pratique, le vecteur moyenne et la matrice de covariance de \mathbf{Y} sont estimés par maximum à vraisemblance, et à noter que dans notre cas, les images hyperspectrales simulées sont bruitées par un bruit gaussien additif de moyenne nulle et de variance σ_n^2 , alors la centralisation et le blanchiment peuvent être remplacés par une étape consiste à diviser la matrice \mathbf{Y} par la variance, alors \mathbf{R} s'écrit,

$$\mathbf{R} = \frac{\mathbf{Y}}{\sigma_n^2} \quad (3.5)$$

Maintenant, supposons P la probabilité de la présence d'un objet dans un pixel considéré, avec $p = N_{total}/M$ où N_{total} est le nombre total des pixels formant les objets et M le nombre des pixels d'un plan 2D de l'image. Supposons que les objets sont rares et par suite la valeur du p est négligeable, d'où nous obtenons l'hypothèse,

$$H_2 : p \geq 0$$

Cela signifie que la présence d'un objet n'affecte pas l'estimation du vecteur moyen et la variance qui maintient ses valeurs 0 et 1 après blanchiment. Nous pouvons donc formuler les hypothèses H_0 et H_1 pour un pixel spectral blanchi \mathbf{r} comme suit,

$$\begin{cases} H_0 : \mathbf{r} = \mathbf{n} \sim \mathcal{N}(0, \mathbf{I}_{n_3}) \\ H_1 : \mathbf{r} = \mathbf{t}_B + \mathbf{n} \sim \mathcal{N}(\mathbf{t}, \mathbf{I}_{n_3}) \end{cases} \quad (3.6)$$

Avec, $\mathbf{t}_B = \mathbf{D}^{-\frac{1}{2}} \mathbf{U}^T \mathbf{t}$ est le vecteur d'intensité spectrale des objets après blanchiment.

3.2.3 Masque de Condition Initiale (MCI)

Le MCI est introduit dans l'algorithme pour le rendre non-supervisé. Il est obtenu par le seuillage des données obtenues par la méthode RX appliquée sur les données blanches avec,

$$\Lambda_{RX}(\mathbf{r}_i) = \|\mathbf{r}_i\|_2^2 \underset{H_0}{\overset{H_1}{\gtrless}} \eta \quad (3.7)$$

Si l'hypothèse H_2 est vérifié, c.à.d que les objets sont rares dans l'image et pour un nombre des échantillons $M \rightarrow \infty$, ceci signifie que les vecteurs blanches $\mathbf{r}_1, \dots, \mathbf{r}_{n_3} \sim \mathcal{N}(0, 1)$, et donc $\Lambda_{RX}(\mathbf{r}_i) = \sum_{j=1}^{n_3} \mathbf{r}_{i,j}^2$ suit une distribution chi-deux centré ($\chi_{n_3}^2$) de n_3 degré de liberté, par suite le seuil η sera calculé de la relation du taux de fausse alarme fixe κ suivante,

$$\kappa = \int_{\eta}^{\infty} p(\mathbf{r}/H_0) d\mathbf{r} = \int_{\eta}^{\infty} f_{\chi_{n_3}^2}(\mathbf{r}) d\mathbf{r} \quad (3.8)$$

où $p(\mathbf{r}/H_0)$ est la probabilité qu'un pixel spectral \mathbf{r} appartenant au fond sera détecté et $f_{\chi_{n_3}^2}(x)$ est la densité de probabilité de la loi chi-deux de degré de liberté n_3

Une fois le seuil η est calculé, le masque de condition initiale est obtenu par un simple opération du seuillage tel que,

$$\begin{cases} \Lambda_{RX}(\mathbf{r}_i) \geq \eta \Rightarrow MCI(i) = 1 \\ \Lambda_{RX}(\mathbf{r}_i) < \eta \Rightarrow MCI(i) = 0 \end{cases} \quad (3.9)$$

3.2.4 Poursuite de Projection : FastICA

Après la génération de MCI, l'indice du pixel le plus anormale au sens du RX est cherché selon,

$$i^* = \underset{i}{argmax}(\Lambda_{RX}(\mathbf{r}_i)) \quad (3.10)$$

L'indice de ce pixel est utilisé comme point de départ de FastICA adopté pour déterminer les projecteurs \mathbf{w} . Ces projecteurs sont liés aux anomalies en supposant qu'un pixel anormale à une valeur de kurtosis maximale (*cf. Annexe C*) et qu'ils sont orthogonaux entre eux pour éviter la convergence dans une même direction, d'où nous formulons les hypothèses suivantes,

H_3 : \mathbf{w} est parallèle à $\mathbf{t}_B \Rightarrow \mathbf{w}$ maximise localement le kurtosis.

H_4 : Les spectres d'anomalies sont proche d'orthogonalités dans l'espace blanchi.

Une pas primaire de l'algorithme FastICA est l'initialisation d'un projecteur selon le critère de départ $MCI(i^*) = 1$, si ce condition n'est pas satisfait, c.à.d, $MCI(i^*) = 0$ alors pas des objets anormales dans l'image. L'algorithme 1 suivant montre l'étape de FastICA utilisé dans la méthode :

Algorithm 1 FastICA avec un approche de déflation

1: **while** $MCI(i^*) = 1$ **do**

2: Initialisation du projecteur \mathbf{w}_j normalisé.

$$\mathbf{w}_j = \frac{\mathbf{r}_{i^*}}{\|\mathbf{r}_{i^*}\|_2} \quad (3.11)$$

3: itération : $l = 1$

4: **while** $|(\mathbf{w}_j^{(l)})^T \mathbf{w}_j^{(l-1)}| \simeq 1$ (*Test de convergence de \mathbf{w}*) **do**

$$\mathbf{w}_j^{(l)} = \frac{1}{M} [\mathbf{R}g(\mathbf{R}^T \mathbf{w}_j^{(l)})] - 3\mathbf{w}_j^{(l)} \quad (3.12)$$

$$\mathbf{w}_j^{(l)} = \mathbf{w}_j^{(l)} - \mathbf{W}\mathbf{W}^T \mathbf{w}_j^{(l)} \quad (3.13)$$

$$\mathbf{w}_j^{(l)} = \frac{\mathbf{w}_j^{(l)}}{\|\mathbf{w}_j^{(l)}\|_2} \quad (3.14)$$

$l = l + 1$;

5: **end while**

6: Ajout de \mathbf{w}_j sur les colonnes de la matrice \mathbf{W} .

7: Projection des données sur la matrice \mathbf{W} ,

$$\tilde{\mathbf{R}} = (\mathbf{I}_{n_3} - \mathbf{W}^T \mathbf{W}) \mathbf{R} \quad (3.15)$$

8: Détermination du pixel le plus anormale dans $\tilde{\mathbf{R}}$.

9: **end while**

L'équation (3.12) est rapprochée de celle du kurtosis en choisissant la fonction non-quadratique $g = (\cdot)^3$ [2], elle est utilisée pour calculer les projecteurs \mathbf{w}_j . L'équation (3.13) est celle de l'approche de déflation qui est introduit dans l'algorithme pour garantir l'orthogonalité entre les projecteurs et par suite la discrimination entre les classes spectrales. L'étape de normalisation (équation 3.14) maintient la variance des données projetées constante ($variance=1$). A chaque fois un projecteur est déterminé, les données hyperspectrales seront projetées sur ce projecteur (équation 3.15) et les mêmes étapes de l'algorithme seront répétées jusqu'au la condition $MCI(i^*) = 1$ ne sera plus satisfaite. Finalement, nous obtiendrons une matrice \mathbf{W} , contient dans ces colonnes les projecteurs orthogonaux obtenus, de dimensions $n_3 \times J$ avec J est le nombre des classes spectrales des objets de l'image.

3.2.5 Seuillage des cartes de détection

Si les hypothèses H_2 et H_4 sont vérifiées, c.à.d, les projecteurs sont orthogonaux et normalisés et la présence des objets est rare donc la projection conserve la loi de probabilité normale centré réduite du fond, et alors les colonnes de la matrice des données projetées (équation 3.15) $\tilde{\mathbf{R}} \sim \mathcal{N}(0,1)$. Donc, même que le seuil η des MCI's, le seuil η_c des cartes de détection sera déterminé de la relation du taux de fausse alarme constante, nous avons donc,

$$\kappa = \int_{\eta_c}^{\infty} f_{\mathcal{N}(0,1)}(\tilde{\mathbf{r}}) d\tilde{\mathbf{r}} \quad (3.16)$$

où $\tilde{\mathbf{r}}$ est le pixel projeté et $f_{\mathcal{N}(0,1)}(\tilde{\mathbf{r}})$ est la densité de probabilité de la loi normale de moyenne nulle et de variance 1.

3.2.6 Unification des classes

En cas où l'hypothèse H_4 n'était pas parfaitement satisfaite, la contrainte d'orthogonalité permet l'interférence entre les classes spectrales et donc un pixel anormal d'un objet peut apparaître dans plusieurs masques de détection. Pour surmonter ce problème, une étape de discrimination entre les J classes est ajoutée après la détermination des cartes de détection,

$$\hat{j}^* = \underset{j \in \Omega}{\operatorname{argmax}}(\mathbf{r}_i^T \mathbf{w}_j) \quad (3.17)$$

Avec Ω est l'ensemble des classes conjointement associées *a priori* au pixel d'indice i .

3.2.7 Déblanchiment des données

Cette étape est supplémentaire, elle permet de visualiser les projecteurs de la matrice \mathbf{W} de l'espace blanchie dans l'espace directe, alors supposons que la matrice de blanchiment est \mathbf{B} avec,

$$\mathbf{B} = \mathbf{D}^{-\frac{1}{2}} \mathbf{U}^T \quad (3.18)$$

Donc la matrice de déblanchiment \mathbf{F} sera,

$$\mathbf{F} = \mathbf{U} \mathbf{D}^{\frac{1}{2}} \quad (3.19)$$

Et par suite un vecteur dans l'espace directe \mathbf{V}_j est obtenu à partir la relation suivante :


$$\mathbf{V}_j = \mathbf{F} \mathbf{w}_j \quad (3.20)$$

3.3 Application de la Poursuite des Composantes Anormales


La poursuite des composantes anormales est appliquée sur deux types des images hyperspectrales bruitées :

1. HSI avec des objets étendus tronqués ;
2. HSI avec des objets étendus ;


L'intérêt de l'application de la méthode sur ces deux types d'objets est l'étude de la performance de la poursuite des composantes anormales à la détection. Pour avoir ces objets, nous utilisons l'algorithme de la simulation des images hyperspectrales présenté dans la *partie* (1.6), puis nous réalisons une opération du masquage par deux masques différents. Le premier est obtenu par un seuillage géométrique (similaire à un seuillage d'intensité par un seuil à σ) pour les objets étendus tronqués et par un autre rapproché d'un seuillage 3σ pour les objets étendus, avec σ l'écart-type de la fonction gaussienne utilisée dans la configuration aléatoire des intensités spatiales des objets. Ces paramètres signifient que nous sélectionnons un pourcentage de 68.2% , c.à.d, les valeurs des fortes intensités pour le cas d'un objet tronqué, et 99.7% pour un objet étendu et donc les faibles intensités sont prises en compte (*figure 3.1*).



(a)



(b)



(c)

FIGURE 3.1 – Représentation des objets : (a) Shématisation de découpage de la fonction gaussienne en fonction de l'écart-type σ , (b) objet étendu tronqué, (c) Objet étendu.

Dans ce qui suit, nous montrerons les résultats de la méthode appliquée sur des images hyperspectrales synthétiques bruitées par différents niveaux du bruit pour chaque type d'objets.


3.3.1 Résultats expérimentaux et discussions

Des images hyperspectrales synthétiques de dimensions $200 \times 200 \times 200$ sont utilisées expérimentalement pour tester la détection spatiale et spectrale de la méthode pour les deux cas des objets :


- (a) Objets étendus tronqués ;
- (b) Objets étendus ;

a) Cas d'objets étendus tronqués


La figure (3.2) montre les images hyperspectrales moyennées sur toutes les bandes spectrales avant et après bruitage. Ces images sont bruitées par un bruit blanc gaussien d'écart-type $\sigma_n = 0.1, 0.8$ et 3 respectivement.




(a) HSI 1




(b) $\sigma_n=0.1$




(c) HSI 2



(d) $\sigma_n=0.8$



(e) HSI 3



(f) $\sigma_n=3$

FIGURE 3.2 – Images hyperspectrales des objets étendus tronqués à étudiées. A gauche : les HSI's initiales : HSI 1 (a), 2(c) et 3 (e), chacune contient un nombre des objets tel que, HSI 1 et HSI 2 inclus 5 objets, HSI 3 inclus 7 objets. A droites : les images hyperspectrales bruitées avec l'écart type du bruit $\sigma_n=0.1$ (b), $\sigma_n=0.8$ (d) et $\sigma_n=3$ (f).

Chaque image contient un nombre d'objets elliptiques où chaque objet appartient à une classe spectrale, ceci signifie que les signatures spectrales des pixels d'un même objet ont la même localisation sur l'axe des bandes. Dans les figures ci-dessous nous montrons comme vérité terrain les signatures spectrales des pixels centraux des objets de chaque image hyperspectrale et dans les tableaux, les paramètres spectraux des objets : la localisation spectrale z et la largeur spectrale β (cf. partie (1.6.2, équation (1.6.2))).




FIGURE 3.3 – *Signatures spectrales des objets de HSI 1.*

Classe	1	2	3	4	5
z	105	123	124	153	159
β	4	6	6	3	8

TABLE 3.1 – *Paramètres spectraux des objets de HSI 1.*




FIGURE 3.4 – *Signatures spectrales des objets de HSI 2.*

Classe	1	2	3	4	5
z	64	72	76	87	170
β	9	7	8	10	8

TABLE 3.2 – *Paramètres des objets de HSI 2.*





FIGURE 3.5 – *Signatures spectrales des objets de HSI 3*

Classe	1	2	3	4	5	6	7
z	11	13	15	21	40	62	67
β	3	5	1	5	10	3	3


TABLE 3.3 – *Paramètres des objets de HSI 3.*

La détermination du masque de condition initial est une étape très importante dans la poursuite des composantes anormales. Le masque contrôle la détermination des projecteurs et forme le critère d'arrêt qui rend toute la méthode non-supervisée. Alors, le seuil de détection doit être précis et par suite le choix du taux de fausse alarme (κ) à partir duquel cet seuil est calculé (*cf. équation 3.8*).


Le masque de condition initiale (*figure 3.6*) de chaque image est obtenu après seuillage des données à la sortie de l'algorithme RX. Les seuils de binarisation sont calculés pour chaque image pour un taux de fausse alarme fixé à une valeur $\kappa = 10^{-6}$ choisie après plusieurs tests expérimentaux. En plus, à noter qu'un nombre des pixels appartenant à un objet de l'image hyperspectrale est suffisant pour sa détection.




(a) Masque VT 1




(b) MCI 1




(c) Masque VT 2



(d) MCI 2



(e) Masque VT 3



(f) MCI 3


FIGURE 3.6 – *Masques binaires. A gauche : les masques (Vérité Terrain) : Masque VT 1 (a), 2 (c) et 3 (e) des images hyperspectrales avant bruitage . A droites : les masques de condition initiale obtenus par le seuillage des données RX pour un TFAC " $\kappa = 10^{-6}$ ", MCI 1(b) pour HSI 1, MCI 2(d) pour HSI 2 et MCI 3(f) pour HSI 3.*

En prenant ça comme une base et pour cette valeur de TFAC choisie, nous pouvons dire que l'opération du seuillage est performante pour un niveau de bruit faible (*figure 3.6(b)*), et cette performance décroît lorsque le bruit sera de plus en plus fort (*e.g. figure 3.6(f)*).


Une fois les MCI's sont calculés, le pixel le plus anormal dans chaque image sera le point de départ de l'algorithme FastICA sous condition que les valeurs de pixels dans les

MCI's de même indice i^* ne sont pas nulles. Cet algorithme connu par sa convergence rapide consiste à chercher les projecteurs orthogonaux qui permettent d'identifier les objets dans les images hyperspectrales. Chaque projecteur déterminé est associé à une classe spectrale, alors pour un pixel de signature spectrale gaussienne localisée sur une bande z et de largeur β , nous attendons un projecteur d'une forme gaussienne, et de même paramètres spectrales.


Les figures 3.7 à 3.9 présentent les projecteurs obtenus par FastICA pour chaque images hyperspectrales et les tableaux 3.4 à 3.6 montrent la vérité terrain, les paramètres spectraux des projecteurs (\hat{z} et $\hat{\beta}$) obtenus par la détection, ainsi que le nombre des itérations nécessaire pour la convergence de chacun d'eux.




(a) $V_1, \hat{z}=105$




(b) $V_2, \hat{z}=123$



(c) $V_3, \hat{z}=126$



(d) $V_4, \hat{z}=153$




(e) $V_5, \hat{z}=159$


FIGURE 3.7 – Projecteurs obtenus par FastICA appliqué sur l'image HSI 1.

Classe	1	2	3	4	5
z	105	123	124	153	159
\hat{z}	105	123	126	153	159
β	4	6	6	3	8
$\hat{\beta}$	4	6	5	4	8
itération	3	3	3	3	4


TABLE 3.4 – Paramètres spectraux détectés des objets de HSI 1.




(a) $V_1, \hat{z}=65$



(b) $V_2, \hat{z}=74$



(c) $V_3, \hat{z}=85$




(d) $V_4, \hat{z}=170$


FIGURE 3.8 – Projecteurs obtenus par FastICA appliqué sur l'image HSI 2.

Classe	1	2	3	4	5
z	64	72	76	87	170
\hat{z}	65	74	74	85	170
β	9	7	8	10	8
$\hat{\beta}$	8	6	-	10	8
itération	3	5	-	7	5

TABLE 3.5 – Paramètres spectraux détectés des objets de HSI 2. Les symboles "-" signifient que le classe spectrale n'est pas détectée.



(a) $V_1, \hat{z}=11$




(b) $V_2, \hat{z}=15$

FIGURE 3.9 – *Projecteurs obtenus par FastICA appliqué sur l'image HSI 3.*


Classe	1	2	3	4	5	6	7
z	11	13	15	21	40	62	67
\hat{z}	11	-	15	-	-	-	-
β	3	5	1	5	10	3	3
$\hat{\beta}$	3	-	1	-	-	-	-
itération	5	-	4	-	-	-	-

TABLE 3.6 – *Paramètres spectraux détectés des objets de HSI 3.*


Finalement, la discrimination spectrale entre les objets aura lieu par la carte de détection et de discrimination. Les données hyperspectrales blanchies représentées par la matrice \mathbf{R} seront projetée sur la matrice \mathbf{W} de dimensions $n_3 \times J$ qui contienne dans ses colonnes les J projecteurs \mathbf{w}_j . La matrice des données projetées $\tilde{\mathbf{R}}$ résultante contient dans ses lignes les différentes classes spectrales. La carte de détection et de discrimination est obtenue par le seuillage par un seuil η_c fixe déterminé à partir de la relation du TFAC (l'équation (3.16)). La figure (3.10) présente les cartes de discrimination initiales (vérité terrain) et les cartes calculées.




(a) Carte de Discr 1(VT)




(b) Carte de Discr 1(DET)




(c) Carte de Discr 2(VT)



(d) Carte de Discr 2(DET)



(e) Carte de Discr 3(VT)



(f) Carte de Discr 3(DET)

FIGURE 3.10 – Carte de détection et de discrimination, cas d'objets étendus tronqué. A Gauche : les cartes de discrimination de vérité terrain (VT) des HSI's contenant les objets. A Droite : les cartes de discrimination déterminées (DET) par la PCA.

En ce qui concerne la détection spectrale des objets, les résultats montrés permettent de déduire l'indépendance entre la performance de la détection et le niveau du bruit au sens de la localisation spectrale et les largeurs des spectres, c.à.d que lorsque un projecteur est déterminé, ses paramètres spectraux correspondent parfaitement aux paramètres de la classe spectrale qu'il caractérise. Néanmoins, dans certains cas où la localisation spectrale de plusieurs classes sont proches, par exemple $z = 13$ et $z = 15$, et pour un niveau de bruit élevé, l'algorithme FastICA ne peut pas les distinguer du fait que les

projecteurs seront déformés à cause du bruit, alors que l'algorithme les considère comme une seule classe, ceci est montré dans la carte de discrimination de la *figure (3.10(d))*. En plus, cet effet nous permet de conclure à partir des *figures (3.6(f))* et *(3.10(f))* qu'un objet qui n'était pas détecté dans le MCI peut apparaitre dans la carte de discrimination. Il est important aussi de trouver la dépendance entre les formes des projecteurs et le niveau de bruit d'une part, et avec l'intensité de l'objet d'une autre part. Par exemple, nous remarquons que les projecteurs de la *figure (3.8)* de l'image *HSI 2* où $\sigma_n = 0.8$ sont plus bruités que ceux de l'image *HSI 1* où $\sigma_n = 0.1$, de plus, nous pouvons distinguer dans l'ensemble des projecteurs de chaque image, un projecteur qui est le plus bruité, ce projecteur correspond à l'objet d'intensité faible qui est proche de celle du bruit ajouté. Et dans certains cas spécifiques, lorsque le niveau du bruit est très élevé, des projecteurs ressemblant au bruit blanc gaussien seront obtenus, comme c'est le cas pour l'image *HSI 3* où une fausse alarme (pixel du fond) est détectée dans le MCI (*figure 3.11*).




FIGURE 3.11 – *Projecteur d'une fausse alarme : (a) Fausse alarme apparait dans le MCI (entourée en rouge) , (b) projecteur de la forme du bruit gaussien.*

En ce qui concerne la détection spatiale des objets tronqués, la performance de la méthode est étudiée par les courbes ROC (*Receiver Operating Characteristic*), chacun est calculé pour 200 expériences. Ce sont des courbes paramétriques dont les paramètres sont le taux de fausse alarme désiré et le nombre de bandes spectrales pour un taux de fausse alarme fixe afin de tester la dépendance de la troisième dimension du cube de donnée et la performance de PCA. Pour les différentes valeurs du paramètres, nous intéressons à la mesure de :

$$P_d = \frac{\text{Nombre de pixels d'objets détectés}}{\text{Nombre total des pixels d'objets}} \quad (3.21)$$

$$P_{fa} = \frac{\text{Nombre de pixels du fond détectés}}{\text{Nombre total des pixels du fond}} \quad (3.22)$$

Avec P_d est la probabilité de détection et P_{fa} la probabilité de fausse alarme expérimentale.

Plusieurs courbes ROC correspondent à la PCA sont :

- Courbe ROC qui décrit la probabilité de détection P_d d'objets étendus tronqués en fonction de TFAC (*figure 3.12*).

- Courbe ROC qui décrit la probabilité de fausse alarme expérimentale P_{fa} en fonction de TFAC (*figure 3.13*).
- Courbe ROC qui décrit la probabilité de détection P_d en fonction de nombre des bandes de HSI (*figure 3.14*).

Pour réaliser ces tests, nous fixons les paramètres de la simulation des images hyperspectrales d'une façon à avoir un seul objet étendu tronqué de caractéristiques fixes (dimensions, orientation, ...), ceci pour pouvoir évaluer la robustesse de la détection en fonction du rapport signal/bruit (SNR), où le SNR d'une image est déterminé par la relation suivante,

$$SNR = \frac{\frac{1}{n_3 \times M} \sum_{i=1}^{n_3} \sum_{j=1}^M t^2(i, j)}{\sigma_n^2} \quad (3.23)$$

$$SNR_{dB} = 10 \times \log_{10}(SNR) \quad (3.24)$$




FIGURE 3.12 – *Courbes ROC : Probabilité de la détection P_d en fonction de TFAC pour $SNR = 0.8, -5$ et -15 dB. La courbe montre la performance de la détection pour des niveaux du bruit faibles ($SNR = 0.8$ dB) et la décroissance de cette performance lorsque le niveau augmente ($SNR = -15$ dB).*

A partir de ces courbes, nous pouvons déduire la suite :

1. La PCA est une méthode robuste pour la détection d'objets étendus tronqués dans les images hyperspectrales pour des niveaux du bruit faible (SNR élevé), cette robustesse décroît plus la valeur du SNR s'affaiblit. Il est remarqué que pour les valeurs de $SNR \geq -5$ dB la probabilité de détection est presque la même et donc cette méthode n'est affectée que par un bruit très fort.




FIGURE 3.13 – Courbes ROC : Probabilité de fausse alarme P_{fa} en fonction de TFAC pour $SNR = 0.8, -5$ et -15 dB. La correspondance des probabilités de fausse alarme expérimentales pour tous les niveaux du bruit montre la performance du processus de taux de fausse alarme constant.

2. Le choix de taux de fausse alarme κ présente certaines limitations. Une valeur du $\kappa \leq 10^{-6}$ influe négativement sur la capacité de la méthode à la détection de tous les pixels des objets d'un part, et d'un autre, une valeur $\kappa \gg 10^{-4}$ augmente le nombre des fausses alarmes non désirées, entre ces deux limites une valeurs optimale de $\kappa = 10^{-4}$ permet d'avoir la meilleur performance avec une probabilité P_{fa} négligeable pour une image hyperspectrale de dimensions $200 \times 200 \times 200$.
3. La correspondance des probabilités de fausse alarme expérimentales pour tous les niveaux du bruit signifie que le modèle des donnée est invariant pour les niveau du bruit choisis et donc la performance du processus de taux de fausse alarme constante.

Finalement, un test de la performance de PCA est réalisé pour l'étude de sa validité en fonction de nombre de bandes (n_3) de l'image hyperspectrale, le taux de fausse alarme est fixé à la $\kappa = 10^{-4}$. La courbe de la *figure (3.14)* montre l'efficacité de la méthode à cette valeur de TFAC pour les images d'un nombre de bandes entre $100 \leq n_3 \leq 800$. Cependant, elle n'est pas robuste pour les SNR faibles en cas des image où $n_3 \leq 100$, et pour tous les valeurs de SNR choisie en cas d'une image hyperspectrale de $n_3 \geq 800$. Ces résultats montre une autre limitation de la poursuite des composantes anormales au niveau du modèle statistique de $\mathbf{\Lambda}_{RX}$ qui ne sera pas la loi chi-deux pour ce nombre des bandes, ce qui affecte le calcul du seuil η pour un TFAC donnée.





FIGURE 3.14 – Courbes ROC : Probabilité de détection des objets quasi-ponctuels en fonction du nombre de bandes n_3 pour $SNR = 0.8, -5$ et -15 dB à une valeur de TFAC $\kappa = 10^{-4}$. Ce courbe montre une robustesse de la "PCA" lorsque le nombre de bandes $100 \leq n_3 \leq 800$, et une limitation de la méthode pour un nombre de bandes différent.

b) Cas d'objets étendus


Dans cette partie, nous montrons les résultats de l'application de PCA sur un autre type des objets : les objets étendus.

La *figure (3.15)* montre un exemple d'une image hyperspectrale moyennée sur toutes les bandes spectrales avant et après bruitage par un bruit d'écart-type $\sigma_n = 0.1$, et la *figure (3.16)* présente les deux cartes de discrimination, la carte de la vérité terrain et la carte obtenue pour un taux de fausse alarme fixe $\kappa = 10^{-6}$.

Pareil à celle des résultats de la détection spectrale d'objets tronqués pour un niveau du bruit faible, la méthode permet une détection robuste des paramètres spectraux d'objets étendus (*tableau 3.7*).




(a) HSI 4




(b) $\sigma_n=0.1$

FIGURE 3.15 – Images hyperspectrales des objets étendus à étudiées. A gauche : L'image hyperspectrale initiale contient 5 objets. A droites : l'images hyperspectrale bruitée avec l'écart type du bruit $\sigma_n=0.1$.



(a) Carte de Discr (VT)



(b) Carte de Discr (DET)

FIGURE 3.16 – Carte de détection et de discrimination, cas d'objets étendus. A Gauche : la cartes de discrimination de vérité terrain (VT) de HSI. A Droite : la carte de discrimination déterminée (DET) par la PCA.

Classe	1	2	3	4	5
z	76	115	127	137	170
\hat{z}	76	115	127	138	170
β	10	4	3	10	3
$\hat{\beta}$	9	4	3	9	3
itération	3	3	3	3	3

TABLE 3.7 – Paramètres spectraux VT et détectés des objets étendus de HSI 4.

La robustesse de la détection spatiale des objets étendus est examinée par les courbes ROC qui montre la probabilité de détection en fonction du taux de fausse alarme fixe. Les courbes de la figures (3.17) montrent que la PCA n'est pas valide pour ce type d'objet même pour un faible niveau du bruit ($SNR = 0.8 \text{ dB}$). L'invalidité de la méthode dans ce cas revient aux faibles valeurs d'intensités des pixels lorsqu'on s'éloigne du centre




FIGURE 3.17 – Courbes ROC : Probabilité de détection P_d en fonction de TFAC pour $SNR = 0.8, -5$ et -15 dB. Mauvaise performance de la méthode pour tous les niveaux du bruit.

de l'objet et qu'ils ne sont pas prise en compte par la méthode, par exemple, la carte de discrimination obtenu (figure 3.16(b)) présente les objets comme ils sont étendus tronqués, alors la détection de tous les pixels des objets n'était pas un succès.

3.4 Conclusion

Dans ce chapitre, nous avons explicité les étapes de la poursuite des composantes anormales et nous avons présenté les résultats de l'application de cette méthode sur deux types des objets : étendus et étendus tronqués, puis nous avons étudié la performance de la détection par les courbes ROC dans les deux cas. Les résultats ont montré l'efficacité de cette méthode au sens de l'identification des paramètres spectraux des objets détectés en présence du bruit, et une performance variée selon le niveau de bruit au sens de la détection spatiale. Les courbes ROC qui ont été présentés ont permis de trouver le domaine de validité de la PCA et donc ses limitations au niveau de choix du taux de fausse alarme, du niveau de bruit, du nombre des bandes de l'image et de l'intensité spectrale des cibles à détecter.

Conclusion Générale

Le stage réalisé porte sur une thématique concernant l'analyse non-supervisée des images hyperspectrales bruitées pour la détection d'objets diffus : étendus et tronqués. Ce manuscrit a présenté les informations en détail sur le sujet.

Dans le premier chapitre, nous avons présenté en générale le principe de l'imagerie hyperspectrale et les facteurs qui interviennent dans la formation des images hyperspectrales, concernant les effets de l'environnement et du systèmes d'acquisition (PSF et LSF). Dans la simulation annoncée, les objets diffus sont modélisés selon le processus de poisson marqué dont les configurations sont définis par ellipses et les intensités suit une loi gaussien et la réponse du système d'acquisition est supposée impulsionnelle pour éviter la complexité de la simulation, ce qui est pris en considération est seulement le bruit du fond venant des conditions de la scène modélisé par un bruit blanc gaussien. En réalité, les facteurs de système d'acquisition (PSF et LSF) ont une grande influence sur la qualité des images et le modèle des données hyperspectrales et donc il contraint la méthode de détection à utiliser.

Dans le deuxième chapitre, la conception générale d'un détecteur est présenté, alors que les détecteurs statistiques qui utilisent le test des hypothèses ont comme base le rapport de vraisemblance (LR) d'une distribution spécifique. Plusieurs méthodes sont dérivées de ce rapport et elles sont reliées avec une un algorithme de taux de fausse alarme constante pour le choix automatique du seuil de détection η . En ce qui concerne ces méthodes, ils sont réparties en deux catégories, supervisées comme le AMF, le ACE, *etc*, basées sur la connaissance des spectres des objets cherchés et non-supervisées comme l'algorithme RX, DWEST-RX, WRX, *etc*, c'est vrai que la performance des méthodes supervisée est plus grande puisqu'on cherche des spectres pré-définies, mais le besoin des méthodes automatiques et l'absence des connaissances suffisantes des objets étudiés favorisent les méthodes non-supervisées.

Dans le troisième chapitre, nous nous intéressons à la problématique de détection des deux catégories des objets diffus. Nous avons également appliqué la "poursuite des composantes anormales" proposée par (A. Huck, 2010). Cette méthode non-supervisée qui combine l'algorithme RX et la poursuite de projection (PP) sous le critère de maximisation de Kurtosis. Cette méthode a montré d'un part, sa capacité à la détection et la discrimination entre les classes spectrales gaussiennes des objets en présence du bruit blanc gaussien, et d'autre part, la robustesse de la détection spatiale des objets tronqués étendus dans les images hyperspectrales bruitées. Les tests réalisés et les courbes ROC

permettent de signaler l'importance du choix de TFAC (κ) qui optimise la détection et ils ont mis en œuvre quelques limitations de la méthode au niveau du nombre de bandes et des intensités des pixels formant les objets.

Dans une étude ultérieure, il pourrait être intéressant de remplacer l'algorithme RX dans la PCA par *Nested Spatial Window* (NSW) [?, 1] En fait, l'utilisation de plusieurs fenêtres glissantes, permettrait l'identification et la localisation des petits objets dans l'images d'une part, et la détections d'objets de faible intensité. La combinaison de ce type de détecteur avec la poursuite de projection, permet au fur et à mesure d'améliorer la capacité de détection spectrale et spatiale des objets étendus ainsi que les ponctuels dans des HSI's bruitées.

Démonstration du modèle du système HSI

Proposition 1. *Considérons les fonctions $\mathbf{X}, \mathbf{I}, \mathbf{H} \in \mathbb{R}^{n_1 \times n_2 \times n_3}$ définies comme : $X(x, y, z) = I(x, y, z) * H(x, y, z)$, et supposons que la fonction $H(x, y)$ est séparable de sorte que $H(x, y, z) = h_0(x, y) * h_\lambda(z)$, alors \mathbf{X} peut être représenté par :*

$$X(x, y, z) = [I(x, y, z) * h_\lambda(z)] * h_0(x, y) \quad (\text{A.1})$$

Démonstration. Pour plus de simplicité, nous remplaçons les variables spatiales x, y par le vecteur $\mathbf{s} = (x, y) \in \mathbb{R}^2$ de sorte que \mathbf{X} peut être écrit,

$$X(\mathbf{s}, z) = I(\mathbf{s}, z) * H(\mathbf{s}, z) \quad (\text{A.2})$$

Et pour $H(\mathbf{s}, z) = h_0(\mathbf{s})h_\lambda(z)$ nous avons donc,


$$\begin{aligned} X(\mathbf{s}, z) &= I(\mathbf{s}, z) * [h_0.h_\lambda(z)] \\ &= \int_{\mathbf{u} \in \mathbb{R}^2} \int_{v \in \mathbb{R}} I(\mathbf{u}, v) h_0(\mathbf{s} - \mathbf{u}) . h_\lambda(z - v) \mathbf{d}\mathbf{u} dv \\ &= \int_{\mathbf{u} \in \mathbb{R}^2} h_0(\mathbf{s} - \mathbf{u}) . \left\{ \int_{v \in \mathbb{R}} I(\mathbf{s} - \mathbf{u}, v) . h_\lambda(z - v) dv \right\} \mathbf{d}\mathbf{u} \\ &= \int_{\mathbf{u} \in \mathbb{R}^2} h_0(\mathbf{s} - \mathbf{u}) . \{I(\mathbf{s} - \mathbf{u}, z) * h_\lambda(z)\} \mathbf{d}\mathbf{u} \\ &= \{I(\mathbf{s}, z) * h_\lambda(z)\} * h_0(\mathbf{s}) \end{aligned} \quad (\text{A.3})$$

Finalement, en remplaçant \mathbf{s} par x, y nous trouvons le résultat de l'équation (A.1). □


Simulation des HSI's

Les signaux (objets) elliptiques sont configurés aléatoirement selon plusieurs paramètres (*partie 1.6.2*). Les résultats des étapes de la simulation d'une image hyperspectrale de dimensions $200 \times 200 \times 200$ sont les suivantes :


- *Figure B.1(a)* : Configuration des centres des ellipses (entourés en rouge) par le processus ponctuel marqué de poisson.
- *Figure B.1(b)* : Configuration des axes des ellipses (dimensions géométriques) par la loi uniforme.
- *Figure B.1(c)* : Configuration des orientations des ellipses par la loi uniforme.
- *Figure B.1(d)* : Assigner à chaque ellipse une intensité spatiale et spectrale selon la distribution gaussienne multipliée par un facteur de gain.
- *Figure B.1(e)* : Ajout d'un bruit blanc gaussien de moyenne nulle et de variance σ_n^2 , (ou d'écart-type σ_n , dans la figure $\sigma_n = 0.8$).




(a)




(b)



(c)



(d)



(e)

FIGURE B.1 – *Etapes de la simulation d'une HSI*

Kurtosis

Le Kurtosis [2] est une statistique d'ordre quatre appliquée dans la plupart des algorithmes ICA à cause de sa simplicité. Plus précisément, le Kurtosis est la version normalisée du moment d'ordre quatre. Pour un pixel spectral \mathbf{y} qui suit une distribution de moyenne zéro, le kurtosis est défini par,

$$Kurt(\mathbf{y}) = E[\mathbf{y}^4] - 3\{E[\mathbf{y}^2]\}^2 \quad (\text{C.1})$$

Sa valeur normalisée est déterminée par la relation suivante,

$$Kurt(\mathbf{y}) = \frac{E[\mathbf{y}^4]}{\{E[\mathbf{y}^2]\}^2} - 3 \quad (\text{C.2})$$

Avec, $E[\mathbf{y}^2]$ est la statistique de deuxième ordre (variance de la distribution), alors pour les données blanchies $E[\mathbf{y}^2] = 1$ et l'équation réduite du kurtosis sera,

$$Kurt(\mathbf{y}) = E[\mathbf{y}^4] - 3 \quad (\text{C.3})$$

En général, lorsque la valeur du kurtosis est nulle la distribution est normale, pour une valeur positive : distribution "Leptokurtic" ou "super-gaussienne" et si la valeur est négative : distribution "Platykurtic" ou "sub-gaussienne" (figure C.1).




FIGURE C.1 – Forme de la distribution selon la valeur de kurtosis. Pour $kurtosis > 0$: distribution Leptokurtic, $kurtosis < 0$: distribution Platykurtic et pour $kurtosis = 0$: distribution normale.

Une caractéristique très importante de kurtosis est qu'il est le plus simple statistique pour indiquer la quantité non gaussienne d'une variable aléatoire. On peut montrer que si \mathbf{y} a une distribution gaussienne, sa Kurtosis est nulle. Pour cela, cette quantité est utilisé dans l'algorithme FastICA comme un critère pour trouver les projecteurs correspondants aux profils spectraux des objets d'intérêt.

Bibliographie

- [1] Post-Doc Ola Ahmad. Multidimensional image model and simulation. Technical report, 2015.
- [2] J.Karhunen, A.Hyvarinen, and E.oja. *Independent Component Analysis*. New York :Wiley, 2001.
- [3] F. Chatelain, A. Costard, and O.J.J. Michel. A bayesian marked point process for object detection. Application to MUSE hyperspectral data. *In 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 3628–3631, 2011.
- [4] C. Zhao et al. Global and Local Real-Time Anomaly Detectors for Hyperspectral Remote Sensing Imagery. *Remote Sens.*, 7(6) :3966–3985, 2015.
- [5] D. Manolakis et al. Is There a Best Hyperspectral Detection Algorithm? *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV*, 7334(02) :1–16, 2009.
- [6] F.C Robey et al. A CFAR adaptive matched filter algorithm. *IEEE Transaction On Aerospace And Electronic Systems*, 22 :115–127, 1974.
- [7] H. Kwon et al. Adaptive Anomaly Detection Using Subspace Separation for Hyperspectral Imagery. *Optical Engineering*, 42(11) :3342–3351, 2003.
- [8] L. Gamal et al. Improvement of SAM Land Cover Classification of Airborne Hyperspectral Data Using Expert System. *open journal of remote sensing and positioning*, 1(1) :1–15, 2014.
- [9] M. L. Piepera et al. Hyperspectral Detection and Discrimination Using the ACE Algorithm. *SPIE Proceedings : Imaging Spectrometry XVI*, 8158(07) :1–12, 2011.
- [10] M.Z. Baghbidi et al.
- [11] Q. Guo et al. Weighted-RXD and Linear Filter-Based rxd : Improving Background Statistics Estimation for Anomaly Detection in Hyperspectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6) :2366–2351, 2014.
- [12] S. Paris et al. Détection Tests Using Sparse Models, With Application to Hperspectral Data. *In IEEE Transactions On Signal Processing*, volume 61, pages 1481–1494, 2013.
- [13] S.R.Soufbaf et al. Efficient detection of anomalies in hyperspectral images. *The international Archives of the photogrammetry, Remote Sensing and Spatial information Sciences*, 37(Part.B7) :303–308, 2008.

- [14] Yann FERREC. *Spectro-Imageurs*. Ed. Techniques Ingénieur, 2010.
- [15] A.Huck, M. Guillaume. Asymtotically CFAR- Unsupervised Targeted Detection and Discrimination in Hyperspectral Images With Anomalous-Component Pursuit. *IEEE Transaction On Geoscience And Remote Sensing*, 48(11) :3980–3991, 2010.
- [16] J.T. Casey, J.P Kerekes. Misregistration impacts on hyperspectral target detection. *Journal of Applied Remote Sensing*, 3 :1–11, 2009.
- [17] I.S. Reed, J.D. Mallet, and L.G. Brenna. Rapid convergence rate in adaptive arrays. *IEEE Transaction On Aerospace And Electronic Systems*, AES-10 :853–863, 1974.
- [18] D. Manolakis, D. Marden, and G. Shaw. Hyperspectral image processing for automatic target detection applications. *Lincoln Laboratory Journal*, 14(1) :79–116, 2003.
- [19] F. Racek and T. Balaz. Spectral Angle Mapper as a Tool for Matching the Spectra in Hyperspectral Processing. *Advances in Military Technology*, 7(2) :65–76, 2012.
- [20] A. Cisz, J. Schott. Performance Comparison of Hyperspectral Target Detection Algorithms in Altitude Varying Scenes. *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XI*, 5806 :839–849, 2005.
- [21] G.L. Zhang, C.L. Yang. Anomaly Detection for Hyperspectral Imagery Using Analytical Fusion and RX. *Journal of Information Hiding and Multimedia Signal Processing*, 5(2) :179–186, 2014.